

INSTITUTO TECNOLÓGICO DE COSTA RICA
VICERRECTORIA DE INVESTIGACIÓN Y
EXTENSIÓN

SISTEMA EXPERTO PARA MOTORES ASISTIDO
POR TEMPERATURA
(SEMAT)

Código VIE 5402-1341-1301

Ing. Luis Diego Murillo-Soto, M.Sc.Eng, M.Comp.
M.Sc. Geovanni Figueroa-Mata
M.Sc. Cindy Calderon-Arce
M.Sc. Luis Ernesto Carrera-Retana
Ing. Juan Pablo Arias-Cartín, M.Eng
Ing. Osvaldo Guerrero-Castro¹, MAIE

Sede Central del ITCR, Costa Rica
2017

¹Coordinador

Índice

1. Código y título de Proyecto	3
2. Autores y direcciones	3
3. Resumen	4
4. Introducción	5
4.1. Objetivo general	5
4.2. Objetivos específicos	6
5. Marco Teórico	6
5.1. Reducción de la vida útil	6
5.2. Modelos térmicos	7
5.3. Modelo térmico propuesto	8
5.3.1. Deducción del modelo	9
5.4. Estimación de parámetros	11
5.4.1. Algoritmos bioinspirados	12
5.5. Pérdidas del motor de inducción	14
5.6. Definición de índices	16
5.7. Redes neuronales	17
5.8. Mapas autoorganizados	17
6. Metodología	18
6.1. Construcción de la bancada de pruebas	19
6.2. Implementación de los experimentos y captura datos	19
6.3. Análisis de datos y desarrollo del modelo	21
6.4. Desarrollo del prototipo de SEMAT	23
6.4.1. Clasificador basado en red neuronal	23
6.4.2. Entrenamiento de la red	23
6.5. Implementación y pruebas de campo	25
7. Resultados y discusión de resultados	25
7.1. Cumplimiento de objetivos	25
7.2. Resultado del modelo térmico	26
7.3. Resultado del prototipo	28
7.4. Discusión de resultados	30
7.4.1. Escalamiento entre modelos	32

7.4.2.	Integrar un sistema de razonamiento basado en casos parametrizable para diagnosticar los fallos en los motores	33
7.4.3.	Desarrollo de un paquete de simulación basado en un modelo térmico	33
8.	Conclusiones	34
9.	Recomendaciones	35
	Referencias	35
Apéndice 1.	Trabajos publicados y presentados	39
	Artículo publicado en LACCEI 2014	40
	Artículo publicado en LACCEI 2015	42
	Artículo publicado en CIBIM 2015	44
	Artículo publicado en Tecnología en marcha 2016	53
	Acuse de presentación al CIBIM 2017	70
	Artículo presentado en Congreso CIBIM 2017	71
	Acuse de Tecnología en Marcha 2017	82
	Artículo presentado en Tecnología en Marcha 2017	83
Apéndice 2.	Artículos en proceso	98
	Predicción de la temperatura del rotor de un motor eléctrico, mediante algoritmos bioinspirados	98
	Redundancia en red de sensores	109
	Método para estimar temperatura interna	113
Apéndice 3.	Informes Técnicos	119
	Modelo Térmico General	119
	Implementación de una Red Neuronal	122
	Matrices de RNA “feed-forward”	133
	Variante del algoritmo enjambre de abejas	134
Apéndice 4.	Registro de datos y ejecutable	138

1. Código y título de Proyecto

**Sistema Experto para Motores Asistido por Temperatura
(SEMAT)**

Código VIE 5402-1341-1301

2. Autores y direcciones

Ing. Luis Diego Murillo-Soto, M.Sc.Eng, M.Comp, lmurillo@itcr.ac.cr

M.Sc. Geovanni Figueroa-Mata, gfigueroa@itcr.ac.cr

M.Sc. Cindy Calderon-Arce, ccalderon@itcr.ac.cr

M.Sc. Luis Ernesto Carrera-Retana, lecarrera@itcr.ac.cr

Ing. Juan Pablo Arias-Cartín, M.Eng, jarias@itcr.ac.cr

Ing. Osvaldo Guerrero-Castro, Coordinador, MAIE, oguerrero@itcr.ac.cr

3. Resumen

El desarrollo de sistemas informáticos que tomen decisiones como expertos humanos en un ámbito particular con base en información, es un reto científico/tecnológico según el contexto y en motores eléctricos estos sistemas son prácticamente inexistentes. El proyecto SEMAT busca el desarrollo de un sistema experto que pueda diagnosticar motores eléctricos con la finalidad de mejorar la competitividad de la industria nacional.

Para el desarrollo del sistema experto, este proyecto ha desarrollado una bancada de pruebas automatizada para someter los motores en estudio a distintas pruebas (casos). Además se ha desarrollado y programado el software de captura y análisis de datos, también se realizaron más de 60 pruebas a motores con base a un diseño de experimentos factorial con la idea de estudiar sus distintos comportamientos. Adicionalmente, se aporta un modelo térmico y se trabajó con distintos tipos de algoritmos basados en metaheurísticas con la finalidad de encontrar soluciones al modelo. Sin embargo, los resueltos encontrados no permitieron ser implementados para el desarrollo del motor de inferencia del sistema experto basado en los parámetros de los modelos térmicos. Ante dicha problemática se aporta la definición de nuevos indicadores que son calculados a partir de la potencias desperdiciadas en los motores. Dichos índices son calculados en tiempo real y almacenados por la aplicación informática.

El prototipo de sistema experto utiliza como motor de inferencia una red neuronal tipo feed-forward. Dicha red fue entrenada con distintos casos (experimentos) y los resultados indican que a partir del monitoreo de los índices es posible realizar el diagnóstico del motor tanto en su transitorio térmico como en su estado estable. Esto es sumamente robusto en el sentido que el motor puede ser diagnosticado en sus primeros minutos de operación y no requiere que alcance su estabilidad térmica.

Finalmente el prototipo fue comparado con el equipo comercial, encontrando que el sistema detecta un fallo más que los detectados por el sistema comercial, es decir el sistema comercial no es capaz de detectar sobrecargas térmicas, lo que si realiza el sistema basado en redes neuronales.

Palabras claves: Diagnóstico en motores, modelos térmicos de motores, identificación de parámetros por meta heurísticas, índices de pérdidas, redes neuronales.

4. Introducción

En Costa Rica se carece de información adecuada y suficiente que permita realizar una gestión de mantenimiento del parque de motores eléctricos del sector industrial. La falta de gestión implica un aumento de los costos de producción, reducción de la disponibilidad de los equipos, además de desfavorecer la competitividad de las empresas.

Estudios realizados por FIDE (Fideicomiso para el Ahorro de Energía Eléctrica) han evidenciado prácticas inadecuadas en la reparación de las fallas en estos tipos de motores, las cuales fomentan las pérdidas en el motor y por ende reducen la eficiencia energética del mismo, debido principalmente a la carencia de aplicación de estándares internacionales tales como, Norma IEEE Std. 43, IEEE Std. 432-1992, NEMA MG 1, IEEE 112 y 118, IEEE Std. 85 y otras, que deben emplearse para garantizar y mantener la eficiencia original del motor.

Este proyecto desarrolló un prototipo de sistema experto que diagnóstica las fallas de los motores y contribuye en general a la eficiencia energética del país. El prototipo de sistema experto (SE), esta orientado a detectar y diagnosticar las condiciones anormales en que opera el motor, estas condiciones fuera de rango son conocidas como faltas.

Comercialmente existen sistemas en línea que permiten monitorear un conjunto de variables, pero requiere de una persona experta en el tema, que establezca las variables a medir y la frecuencia de medición. Posteriormente, el experto debe analizar los datos y brindar las recomendaciones generales de los posibles causantes del problema, así como las respectivas acciones correctivas. El costo de monitoreo y mantenimiento actual de un motor asciende a \$800, en tanto adquirir el equipo representa para una empresa una erogación de aproximadamente \$50 000, además se necesita capacitar a un técnico, cuyo costo promedio es de \$22 500 anuales por lo que para una PYME no es posible acceder a dicho servicio. Este tipo de sistema de mantenimiento de monitoreo y diagnóstico está limitado principalmente por:

- Equipo especializado para el monitoreo de alto costo (mayor a \$50 000).
- Experto en el equipo para realizar el diagnóstico.

Este proyecto de investigación aporta un prototipo de sistema experto que muestra la viabilidad técnica de implementar la captura y análisis de los datos en tiempo real con el propósito de realizar el diagnóstico de los fallos. El diagnóstico brindado por el prototipo permite que los técnicos puedan modificar las condiciones de operación del motor y por lo tanto lograr dos efectos: alargar la vida útil o incrementar la eficiencia de la máquina, sin ser experto.

4.1. Objetivo general

Desarrollar un Sistema Experto para la detección y diagnóstico de faltas en motores trifásicos de inducción mediante el monitoreo asistido de variables, empleando un modelo térmico.

4.2. Objetivos específicos

1. Establecer las condiciones de experimentación para obtener los modelos térmicos en motores eléctricos de hasta 5 hp.
2. Caracterizar las señales de funcionamiento de motores eléctricos de distintas potencias sin faltas inducidas.
3. Caracterizar las señales de funcionamiento de motores eléctricos de distintas potencias con faltas inducidas.
4. Evaluar escalamiento entre modelos y generalidad para otros motores.
5. Desarrollar un paquete de simulación basado en un modelo térmico que permite detectar faltas en los motores eléctricos.
6. Integrar un sistema de razonamiento basado en casos parametrizable para diagnosticar las faltas en los motores.
7. Comparar la detección de las faltas empleando prototipo de SEMAT y equipo comercial.

En cuanto al cumplimiento de los objetivos se trabajaron todos ellos, sin embargo los resultados brindados por los objetivo 4 y 5 obligaron a variar la perspectiva de funcionamiento del sistema experto. Es decir el prototipo de sistema ya no funciona por modelos térmicos sino por índices de potencias que son calculados con las señales de los sensores. Se destaca que los índices y el método para calcularlos son un nuevo aporte al estado de conocimiento y se presentan como un alternativa real para el desarrollo de sistemas expertos basados en este tipo de indicadores.

5. Marco Teórico

5.1. Reducción de la vida útil

El calentamiento de los motores puede ocurrir por varios fenómenos, ya sean eléctricos, mecánicos o térmicos. El calentamiento interno repercute de forma directa sobre su vida útil pues los materiales y barnices aislantes del motor se degradan de forma exponencial, por cada $10^{\circ}C$ por encima de la temperatura máxima de la clase del aislamiento la vida útil se reduce a la mitad [1, 2].

$$L_x = L_{100} 2^{(T_c - T_x)/k} \quad (1)$$

donde L_x representa la estimación de la vida útil en la nueva condición de operación, L_{100} es la vida útil proyectada de fábrica, usualmente 20.000 horas, T_x es la nueva temperatura de operación, T_c es la temperatura de la clase del aislamiento y k es una constante definida para cada clase de aislamiento.

Existen varias maneras de estimar la temperatura interna de un motor, estas se podrían clasificar por métodos directos que consisten en medir la zona de

interés con RTDs o termopilas [3], o con pirómetros o termo-grafías, etc, Por otra parte existen otros métodos que utilizan modelos físicos tal como el cambio de la resistencia del devanado del motor [4] o estimación de la temperatura en una zona específica del motor mediante el modelos térmicos [5],[6], [7].

5.2. Modelos térmicos

Para el control y predicción de la temperatura interna de un motor, se han propuesto algunos modelos, de acuerdo con [8] los modelos de primer orden son rápidos y eficientes, presentan una buena estimación de la temperatura y necesitan solamente el valor de la corriente estatórica, pero esta estimación es un promedio general que no permite determinar los puntos calientes de la máquina. En [9] se realiza una comparación entre distintos tipos de modelos de primer orden, los cuales poseen una estructura similar a la ecuación (2)

$$\theta = I^2 R R_{th} \left(1 - \exp \left(\frac{-t}{R_{th} C_{th}} \right) \right) + \theta_A \quad (2)$$

Donde θ y θ_A son las temperaturas interna y ambiental, respectivamente, el término $I^2 R$ representa las pérdidas totales del motor, R_{th} representa una resistencia térmica equivalente y C_{th} representa la capacitancia térmica del motor.

Por otro lado, los modelos térmicos mallados para estados estables permiten predecir la temperatura en zonas específicas de la máquina, con el inconveniente de que la estimación de temperaturas en el transitorio térmico presenta errores de hasta un cien por ciento. Estos modelos en estado estable, tales como los que se plantean en [3, 10, 11], obtienen las temperaturas resolviendo el sistema de ecuaciones lineales dado en (3), donde P es el vector de pérdidas de la máquina, G es la matriz de conductancias térmicas del motor y θ es el vector de temperaturas a calcular.

$$P = G\theta \quad (3)$$

Los modelos térmicos mallados para estados transitorios son aquellos que pueden predecir la temperatura en un punto específico de la máquina, tanto en régimen transitorio como en estado estable. Estos modelos incorporan un tercer vector a la ecuación (3), el cual se forma al multiplicar una matriz C que contiene en su diagonal las capacitancias térmicas de la máquina, por un vector que contiene las derivadas de las temperaturas respecto al tiempo $\frac{d\theta}{dt}$, de tal forma que la expresión general está dada por

$$C \frac{\partial \theta}{\partial t} = P - G\theta \quad (4)$$

Otros modelos más complejos, como los que se plantean en [1, 6, 12], representan el estado transitorio. Estos ofrecen una predicción de la temperatura en

el respectivo nodo, pero para poderla estimar se requiere conocer los materiales, geometrías, dimensiones y masas para calcular cada conductancia térmica entre los nodos y la matriz de capacitancia. Adicionalmente se requiere conocer en forma detallada cada una de las pérdidas reales de la máquina, para esto es necesario realizar pruebas de laboratorio. Cabe señalar que estos inconvenientes también se presentan en los modelos en estado estable, ecuación (3).

Por otro lado la estimación de temperatura con base en parámetros eléctricos, se divide fundamentalmente en dos esquemas. El primer esquema surge del estándar IEEE 112 [4], donde se indica que la variación de la temperatura interna provoca variaciones de las resistencias estáticas y rotóricas del motor en la siguientes proporciones

$$\theta_2 = \frac{R_2}{R_1}(\theta_1 + k) - k \quad (5)$$

R_1 representa la resistencia a la temperatura θ_1 , usualmente medida a temperatura ambiente con motor apagado, R_2 la resistencia a la temperatura θ_2 y k es el coeficiente del material conductor, donde para el cobre es 234.5 y para el aluminio es de 225. Para obtener el valor de las resistencias se utilizan dos métodos, el primero calcula la resistencia aplicando la ley de Ohm a la medición del voltaje y corriente continua (CD). El otro método es la medición directa con puente wheatstone doble, mediante un miliohmímetro. Consecuentemente y dado que el punto más caliente de una máquina es el devanado estático [13], la medición de la resistencia estática es el método más sencillo de estimación de temperaturas.

La desventaja del esquema de medición de la resistencia estática es que es invasivo, ya que requiere de equipamiento adicional y desconectar eléctricamente la máquina. Por tal motivo se han venido desarrollando métodos alternativos de obtención de la resistencia estática a partir de mediciones eléctricas de voltajes y corrientes [8, 14, 15] o frecuencias [16]. La idea de estos trabajos es desarrollar equipos en tiempo real que operen en línea con el motor y que realicen los respectivos cálculos de la estimación de temperatura interna. El principal inconveniente de estos métodos es que estiman la temperatura interna del devanado, pero no estiman el comportamiento de las temperaturas en otras zonas de interés en el motor, tal como la temperatura del núcleo, roles, carcasa, etc.

5.3. Modelo térmico propuesto

El modelo térmico utilizado en este estudio fue propuesto en [6] y [12], ver figura 1. Este modelo se construye a partir de la ecuación general (4) y posee dos nodos llamados θ_s y θ_r que representan la temperatura promedio del estator y del rotor, respectivamente, la temperatura θ_0 se refiere a las temperaturas iniciales de θ_s y θ_r . En el modelo las pérdidas de potencia del motor se representan como fuentes de calor que elevan las temperaturas internas, la fuente del estator es llamada P_s y la del rotor P_r , los capacitores térmicos C_s y C_r representan

la capacidad del estator y rotor para almacenar calor, respectivamente, son el producto de la masa del componente por el calor específico del material.




Figura 1: Modelo térmico de un motor eléctrico de inducción. Adaptado de [6]

5.3.1. Deducción del modelo

A partir la ecuación (4) y del modelo térmico de la figura 1, se obtiene el siguiente sistema de ecuaciones diferenciales de primer orden

$$\begin{bmatrix} C_s & 0 \\ 0 & C_r \end{bmatrix} \begin{bmatrix} \frac{d\theta_s}{dt} \\ \frac{d\theta_r}{dt} \end{bmatrix} = \begin{bmatrix} P_s \\ P_r \end{bmatrix} - \begin{bmatrix} (G_s + G_{sr}) & -G_{sr} \\ -G_{sr} & (G_r + G_{sr}) \end{bmatrix} \begin{bmatrix} \theta_s \\ \theta_r \end{bmatrix} \quad (6)$$

$$\theta(0) = \begin{bmatrix} 0 \\ 0 \end{bmatrix}$$

El modelo dado en (6) se puede reescribir de la forma

$$C_s \frac{d\theta_s}{dt} = P_s - (G_s + G_{sr})\theta_s + G_{sr}\theta_r \quad (7)$$

$$C_r \frac{d\theta_r}{dt} = P_r - (G_r + G_{sr})\theta_r + G_{sr}\theta_s \quad (8)$$

las condiciones $\theta_s(0) = 0$ y $\theta_r(0) = 0$ que indican que el motor inicia a temperatura ambiente.

Despejando θ_r de la ecuación (7), derivando y sustituyendo en (8) se obtiene

$$\theta_r = \frac{C_s \theta'_s + (G_s + G_{sr}) \theta_s - P_s}{G_{sr}} \quad (9)$$

$$\theta'_r = \frac{C_s \theta''_s + (G_s + G_{sr}) \theta'_s}{G_{sr}} \quad (10)$$

Al sustituir (9) y (10) en (8) obtenemos que el sistema de ecuaciones diferenciales es equivalente a la siguiente ecuación diferencial de segundo orden, la cual esta en términos de la temperatura θ_s , únicamente

$$\theta''_s + \alpha \theta'_s + \beta \theta_s = \gamma \quad (11)$$

donde

- $\alpha = \frac{C_r(G_s + G_{sr}) + C_s(G_r + G_{sr})}{C_r C_s}$
- $\beta = \frac{G_s G_r + G_s G_{sr} + G_r G_{sr}}{C_r C_s}$
- $\gamma = \frac{P_r G_{sr} + P_s G_r + P_s G_{sr}}{C_r C_s}$

Por otro lado, al resolver de forma analítica el sistema de ecuaciones diferenciales dado en (6) se obtienen las ecuaciones (12), que modelan la temperatura del estator θ_s y rotor θ_r en función de los parámetros térmicos y del tiempo t .

$$\begin{cases} \theta_s = C_1 \cdot \exp(r_1 t) + C_2 \cdot \exp(r_2 t) + \frac{E}{B} \\ \theta_r = C_3 \cdot \exp(r_1 t) + C_4 \cdot \exp(r_2 t) + \frac{F}{B} \end{cases} \quad (12)$$

donde r_1 y r_2 representan las soluciones de la ecuación característica asociada y además

- $C_1 = \frac{E(r_2 C_s + G_s + G_{sr}) - F G_{sr}}{B C_s (r_1 - r_2)}$
- $C_2 = \frac{E(r_1 C_s + G_s + G_{sr}) - F G_{sr}}{B C_s (r_2 - r_1)}$
- $C_3 = \frac{C_1(r_1 C_s + G_s + G_{sr})}{G_{sr}}$
- $C_4 = \frac{C_2(r_2 C_s + G_s + G_{sr})}{G_{sr}}$

$$\begin{aligned}
\blacksquare B &= \frac{G_s G_r + G_s G_{sr} + G_r G_{sr}}{C_s C_r} \\
\blacksquare E &= \frac{G_r P_s + G_{sr} P_s + G_{sr} P_r}{C_s C_r} \\
\blacksquare F &= \frac{G_s P_s + G_{sr} P_s + G_{sr} P_r}{C_s C_r}
\end{aligned}$$

5.4. Estimación de parámetros

Para estimar los parámetros $[G_s, G_r, G_{sr}, C_s, C_r]^T$ se comparan las respuestas $\tilde{\theta}_s$ y $\tilde{\theta}_r$ del modelo de referencia basado en 12 con las temperaturas medidas obtenidas del motor, cada segundo a lo largo de cada una de las pruebas, θ_s y θ_r . Los parámetros del modelo de referencia se van ajustando iterativamente de manera tal que la diferencia entre las respuestas de ambos modelos sea mínima, en este sentido, el ajuste de los parámetros es un problema de optimización.

De esa manera, los parámetros de la solución analítica del modelo (12) se van ajustando iterativamente de tal forma que dicha diferencia sea mínima. En este sentido, el ajuste de los parámetros es un problema de optimización donde la función objetivo a optimizar es el error cuadrático medio (13), que se obtiene restando los datos experimentalmente medidos θ y la respuesta $\tilde{\theta}$ del modelo térmico (12).

$$\varepsilon = \frac{1}{N} \sum_{i=0}^N \left(\theta(t_i) - \tilde{\theta}(t_i) \right)^2 \quad (13)$$

donde $\theta(t_i) = [\theta_s(t_i), \theta_r(t_i)]^T$ y $\tilde{\theta}(t_i) = [\tilde{\theta}_s(t_i), \tilde{\theta}_r(t_i)]^T$, el t_i indica la temperatura correspondiente en el instante i .

El algoritmo 1 muestra el procedimiento general para el ajuste de parámetros en la predicción de la temperatura del estator y rotor, a partir del modelo térmico.

Algorithm 1: Algoritmo General

Input: $\{\theta(t_i)\}, tol, iterMax$

Output: $[G_s, G_r, G_{sr}, C_s, C_r]^T, \{\tilde{\theta}_s(t_i)\}, \{\tilde{\theta}_r(t_i)\}$

- 1 Calcular $[P_s, P_r]^T$ (Por medio de (27)-(28))
 - 2 **while** $\min\{\varepsilon\} \geq tol$ & $iter \leq iterMax$ **do**
 - 3 Resolver $\min\{\varepsilon\}$ (Por medio de ABC o DE)
 - 4 $[G_s, G_r, G_{sr}, C_s, C_r]^T \leftarrow \arg \min\{\varepsilon\}$
 - 5 Calcular $\{\tilde{\theta}_s(t_i), \tilde{\theta}_r(t_i)\}$ (Por medio de (12))
 - 6 **end**
-

5.4.1. Algoritmos bioinspirados

Debido a la complejidad del problema los métodos clásicos no son la mejor opción y es necesario aplicar otras estrategias de optimización para minimizar el error planteado en la ecuación (13). Para este tipo de problemas se han propuesto y probado con éxito una gran variedad de algoritmos de optimización bioinspirados como: Genetic Algorithm (GA) [17], inspirados en la ley de supervivencia del más fuerte; Particle Swarm (PS), inspirado en el comportamiento social de bandadas de pájaros o cardúmenes de peces; Ant Colony (AC), inspirados en los hábitos alimentarios de colonias de hormigas; Differential Evolution (DE), basado en el principio de selección natural en la supervivencia de especies y, más recientemente, el Artificial Bee Colony, que simula el comportamiento alimenticio de los enjambres de abejas [18].

Artificial Bee Colony (ABC)

Desde su creación en 2005 este algoritmo ha sido aplicado a la solución de una gran cantidad de problemas de optimización [19, 20, 21] y se han propuesto muchas variantes del mismo, como un algoritmo de inteligencia de enjambres que emula el comportamiento de las abejas en la búsqueda y explotación de fuentes de alimento. Define una población de fuentes de alimento modificada por medio de abejas artificiales, con el objetivo de determinar los lugares con un alto recurso de alimento [18, 22].

Las abejas sobrevuelan el espacio de búsqueda, employed and onlooker bees determinan fuentes de alimento con base en su experiencia y la de sus compañeras de colmena, scouts bees eligen fuentes de alimento de manera completamente aleatoria.

Employed bees explotan las fuentes de alimento, guardan su información y la comunican a onlooker bees, con ello las onlookers bees eligen las mejores fuentes que serán explotadas. Cuando alguna fuente de alimento se agota, scouts bees buscan nuevas fuentes para sustituir la que se agotó.

Las fuentes de alimento representan soluciones factibles del problema de optimización y la cantidad de alimento de la fuente corresponde a la calidad de la solución (fitness), la cual es determinada de acuerdo a la cercanía a la colmena, la cantidad de alimento disponible y la facilidad de extraer el alimento.

Las fuentes de alimento iniciales se generan de forma aleatoria por medio de la siguiente fórmula

$$x_{i,j} = \min_j + \text{rand}(0,1) \cdot (\max_j - \min_j) \quad (14)$$

donde $x_{i,j}$ representa el parámetro j de la fuente de alimento (solución) X_i y \min_j y \max_j son las cotas inferior y superior del parámetro j . ABC se organiza en tres etapas:

- (i) Employed bees determinan nuevas soluciones (fuentes de alimento) mediante la ecuación

$$v_{i,j} = x_{i,j} + \psi(x_{i,j} - x_{k,j}) \quad (15)$$

donde cada $v_{i,j}$ representa una fuente de alimento, ψ es un valor aleatorio con distribución uniforme en el intervalo $[-1, 1]$ y k es cualquiera de las fuentes diferente de la fuente i . Se evalúan las soluciones encontradas, se comparan con la solución actual y se conserva la mejor.

- (ii) Cada onlooker bee elige una fuente de alimento X_i con cierta probabilidad P_i , tomando como base el fitness dado por las employed bees. Luego, se calculan nuevas soluciones candidatas por medio de la fórmula (15), se evalúan las soluciones encontradas, se comparan con la solución X_i y se selecciona la mejor.
- (iii) Employed bees con soluciones que no pudieron ser mejoradas se convierten en scout bees, abandonan su solución y buscan nuevas soluciones a partir de la fórmula (14).

Ver algoritmo 2.

Algorithm 2: Artificial Bee Colony Algorithm

```

1  $i \leftarrow 0$ 
2 Initial population:  $\{v_{i,j}\}$ 
3 while  $i \leq iterMax$  do
4    $i \leftarrow i + 1$ 
5   Employed Phase
6   Onlooker Phase
7   Scout Phase
8   Choose the best solution
9 end
```

Differential Evolution (DE)

DE es un algoritmo útil para determinar minimizadores globales de problemas con o sin restricciones, sin el requerimiento de funciones objetivo derivables, continuas, lineales o uniobjetivo. Emula el proceso evolutivo y de supervivencia dado por Genetic Algorithm y Evolutionary Strategies.

Así, dada una población de tamaño $N \geq 4$, donde cada individuo X_i está compuesto por D parámetros, $x_{i,j}^{(k)}$ representa el parámetro j de la solución i en la generación k , donde L_j y U_j son las cotas inferior y superior del parámetro j , respectivamente. DE determina los valores iniciales de los parámetros de manera aleatoria y aplica los operadores de mutación, cruzamiento y selección a cada vector de parámetros de la siguiente manera, en la k -ésima generación:

- (i) Por cada solución i , se seleccionan otras tres soluciones aleatorias i_1, i_2 e i_3 y calcula su donator vector or donator solution, por medio de la fórmula (16).

$$V_i^{(k+1)} = X_{i_1}^{(k)} + M(X_{i_2}^{(k)} - X_{i_3}^{(k)}) \quad (16)$$

donde M es el differential weight (factor de mutación), calculado de manera aleatoria en el intervalo $[0, 2]$.

- (ii) A partir de $X_i^{(k)}$ y $V_i^{(k+1)}$, se genera un trial vector por medio de la siguiente fórmula

$$U_i^{(k+1)} = \begin{cases} V_i^{(k+1)}; & \text{if } rand_{i,j} \leq P \vee j = I_{rand} \\ X_i^{(k)}; & \text{otherwise} \end{cases} \quad (17)$$

donde $rand_{i,j} \sim U[0, 1]$ es la crossover probability, P es una probabilidad dada e I_{rand} es un entero aleatorio tomado del conjunto $\{1, 2, 3, \dots, D\}$, por medio del cual se garantiza que $X_i^{(k)} \neq V_i^{(k+1)}$.

- (iii) Se compara el valor objetivo de cada vector con su respectivo trial vector y se toma el que brinda mejor valor, en el caso de minimización será el que genere un menor valor objetivo

$$X_i^{(k+1)} = \begin{cases} U_i^{(k+1)}; & \text{if } f(U_i^{(k+1)}) \leq f(X_i^{(k)}) \\ X_i^{(k)}; & \text{otherwise} \end{cases} \quad (18)$$

Ver algoritmo 3.

Algorithm 3: Differential Evolution Algorithm (DE)

```

1  $k \leftarrow 0$ 
2 Generate initial parameters
3 while  $k \leq genMax$  do
4   for  $i = 1 : N$  do
5     Mutation
6     Crossover
7     Selection
8   end
9    $k \leftarrow k + 1$ 
10 end
```

5.5. Pérdidas del motor de inducción

El motor eléctrico es un convertidor no ideal de energía eléctrica a mecánica, los motores modernos de alta eficiencia alcanzan valores de conversión de energía de hasta 95 % para potencias superiores a los 50 caballos de fuerza (hp) y para motores con potencias no menores de 3 hp sus eficiencias son superiores a un 90 %. La deficiente conversión de energía provoca el incremento de temperatura interna en la máquina tal y como lo explican los modelos térmicos descritos por [5],[6], [23],[7]. La ecuación (19) muestra que un incremento de las pérdidas en la máquina provoca un decrecimiento de la eficiencia de forma proporcional.

$$\eta = 1 - \frac{P_{loss}}{P_{in}} \quad (19)$$

donde η es la eficiencia y P_{loss} , P_{in} son las potencias por pérdidas y potencia de entrada del motor, respectivamente.

Las potencias por pérdidas son resultado de un deficiente proceso de conversión de energía eléctrica a mecánica. Así, la potencia total de pérdida se calcula como la diferencia entre la potencia de entrada P_{in} y la de salida P_{out} , tal y como se muestra en la ecuación (20)

$$P_{loss} = P_{in} - P_{out} = P_s + P_r + P_{mis} \quad (20)$$

donde P_s representa la pérdida del estator, P_r la del rotor y P_{mis} las potencias mecánica y misceláneas. Además, la potencia por pérdidas del estator P_s se calcula por medio de la ecuación (21), donde P_{cs} es la potencia de pérdida por efecto Joule en los devanados estatóricos y P_{ns} la potencia por pérdidas en el núcleo debido a corrientes parásitas e histéresis.

$$P_s = P_{cs} + P_{ns} \quad (21)$$

$$P_{cs} = R_s(I_a^2 + I_b^2 + I_c^2)(1 + 0,00389(\Delta\theta)) \quad (22)$$

La potencia P_{cs} se calcula como en la ecuación (22), donde R_s es la resistencia estatórica medida a la temperatura ambiente, los términos I_a , I_b , I_c son las corrientes por fase, el término $\Delta\theta$ representa la diferencia de temperatura del devanado estatórico y la temperatura ambiente.

Por otro lado, las potencias por pérdidas del rotor P_r se determina según la ecuación (23), donde s es un número adimensional que se calcula según la ecuación (24), n_{scr} es la velocidad sincrónica y n_{mec} es la velocidad mecánica del motor.

$$P_r = (P_{in} - P_{cs} - P_{ns})s \quad (23)$$

$$s = \frac{n_{scr} - n_{mec}}{n_{scr}} \quad (24)$$

Luego, la pérdida P_{mis} se puede estimar como en la ecuación (25)

$$P_{mis} = \chi(P_{in} - P_{out}) \quad (25)$$

donde χ oscila entre $[0, 0,11]$ según datos de [24], se puede calcular de forma experimental por medio de las pérdidas mecánicas y misceláneas. Dado que las ecuaciones (21) y (23) dependen de P_{ns} , es necesario estimarla. Para ello, se sustituye (21), (23) y (25) en (20) para obtener la potencia del núcleo P_{ns} en términos de parámetros medidos:

$$P_{ns} = \frac{(1 - s - \chi)P_{in} - (1 - s)P_{cs} - (1 - \chi)P_{out}}{(1 - s)} \quad (26)$$

Nuevamente, al sustituir (26) en (21) y (23) se obtienen expresiones que solamente dependen de las mediciones realizadas. De esta forma las expresiones para P_s y P_r , tomando $\chi = 0$, son aproximadas por las expresiones en (27) y (28).

$$P_s \approx P_{in} - \frac{P_{out}}{(1-s)} \quad (27)$$

$$P_r \approx s \frac{P_{out}}{(1-s)} \quad (28)$$

5.6. Definición de índices

El mínimo cambio en las pérdidas de la máquina no solo afecta la eficiencia, sino que esa energía adicional desperdiciada es convertida en calor. Medir la temperatura interna no es suficiente para explicar de donde proviene ese calor.

Se propone utilizar índices que relacionan los distintos tipos de pérdidas de potencia del motor con el fin de utilizarlos para determinar el fallo² o la alteración en la condición de operación del motor, es decir, un fallo en la máquina repercute en su eficiencia y por lo tanto en los índices propuestos.

Se definen cinco índices calculados por medio de las pérdidas del motor expuestas anteriormente. En conjunto, estos índices logran determinar si hay cambios en la carga del motor, alteraciones en el voltaje de alimentación o un calentamiento por pobre ventilación.

Los índices que se proponen son

$$I_{cs} = \frac{P_{cs}}{P_{loss}} \quad (29)$$

$$I_{ns} = \frac{P_{ns}}{P_{loss}} \quad (30)$$

$$I_r = \frac{P_r}{P_{loss}} \quad (31)$$

$$I_{rcs} = \frac{P_r}{P_{cs}} \quad (32)$$

$$I_{rs} = \frac{P_r}{P_s} \quad (33)$$

El índice I_{cs} establece una relación entre las pérdidas que ocurren por efecto Joule entre el devanado estatórico y las pérdidas totales, este índice varía de acuerdo a los cambios en el voltaje de alimentación. A su vez I_{ns} calcula la relación entre la potencia disipada en el núcleo de la máquina y la total desperdiciada. El índice I_r relaciona las pérdidas del rotor entre el total de pérdidas. Los índices I_{rcs} y I_{rs} buscan establecer las relaciones específicas entre dos tipos

²Entiéndase falta y fallo como equivalentes, en el contexto de este trabajo

de pérdidas de potencia, el primer caso establece la relación entre potencias perdidas en el rotor y cobre del estator y el segundo índice relaciona las pérdidas del rotor y el estator.

5.7. Redes neuronales

Una red neuronal artificial es un modelo simplificado del sistema neuronal humano [25],[26]. La unidad más simple de una red neuronal es la neurona artificial, la cual posee dos etapas, la primera suma los productos de la entrada $I(j)$ por el factor de su peso de arco $W(j)$, luego se le suma un factor de polarización llamado bias b . La segunda etapa consiste en utilizar el resultado de la suma anterior y realizar la activación de la neurona mediante una función de transferencia. Existen varios tipos de funciones de activación [27], entre ellas *Sigmoid(a)*, *Logsig(a)*, *Purelin(a)*, para este trabajo se utiliza la llamada *Tansig(a)*, ecuación (34). La figura 2 muestra una representación gráfica del modelo descrito anteriormente y la ecuación (34) su representación algebraica.




Figura 2: Neurona artificial

$$a = \sum_{j=1}^n [W(j)I(j)] + b$$

$$y = Tansig(a) = \frac{2}{1 + e^{-2a}} - 1 \quad (34)$$

5.8. Mapas autoorganizados

Un mapa autoorganizado (SOM) es un tipo de red neuronal artificial, que se entrena utilizando un aprendizaje no supervisado para producir una representación discreta del espacio de las muestras de entrada [25],[26]. Organizándolas o agrupándolas de acuerdo a patrones o características comunes, tomando en cuenta tanto la competitividad, como la cooperatividad entre dichas muestras. En la etapa de competitividad, para cada muestra $I(j)$ se selecciona la neurona con la distancia euclídea más pequeña, según la ecuación (35), donde cada neurona representa una región en el espacio de entrada.

$$i^* = \operatorname{argmin}_i \|w_i - I(j)\| \quad (35)$$

La neurona con vector de pesos más similar a la entrada es la ganadora. Por otro lado, en la etapa de cooperatividad, cada neurona se compara con sus neuronas vecinas, en la cual tanto el vector de pesos de la neurona ganadora es actualizado, por medio de una regla de actualización Δw_i , como el mallado de su vecindario. Para ello se utiliza una función Gaussiana de vecindad Λ , centrada en la neurona ganadora y decreciente respecto a la distancia de la neurona ganadora.

$$\begin{aligned} \Delta w_i &= \alpha \Lambda(i, i^*, \sigma_\Lambda(t)) (I(j) - w_i) \\ \Lambda(i, i^*) &= \exp \left(-\frac{\|r_i - r_{i^*}\|^2}{2\sigma_\Lambda^2} \right) \end{aligned} \quad (36)$$

donde r_i y r_{i^*} representan los nodos del mallado discreto con una topología regular [28].

6. Metodología

A continuación se muestra la metodología seguida en el proyecto SEMAT. Dicha método fue seguida tal cual se presento en el planteamiento del proyecto. La figura 3 indica las etapas seguidas en el transcurso del proyecto.



Figura 3: Metodología seguida en proyecto SEMAT

6.1. Construcción de la bancada de pruebas

Esta sección involucró desde la compra, diseño y construcción del banco de pruebas hasta la gestión del espacio físico en la escuela de Ingeniería Electromecánica para instalar los equipos. Específicamente en esta etapa se realizó:

- Gestión de un espacio físico para realizar experimentos.
- Acondicionamiento del espacio físico para convertirlo en laboratorio.
- El diseño e instalación del circuito eléctrico de potencia para el motor.
- El diseño e instalación de montaje mecánico del motor.
- La instalación de los sensores.
- El diseño y programación del software para las tarjetas de adquisición de datos.
- El diseño y programación del software del usuario.

Es importante señalar que antes del proyecto SEMAT solamente el Instituto Costarricense de Electricidad poseía un laboratorio para la prueba de motores. Gracias a este proyecto el TEC cuenta con un laboratorio para la prueba de motores de potencias por debajo de 5 hp.

El banco de pruebas para motores trifásicos que se construyó se compone de un generador de corriente directa de 5 kW y un banco de resistencias de 7 kW. El banco posee tres auto transformadores monofásicos conectados en estrella para provocar bajos y altos voltajes de alimentación así como desbalances. En la figura 4 se muestra una fotografía parcial del banco de pruebas implementado.

Para interconectar el banco de pruebas con el sistema de adquisición de datos, se desarrolló una aplicación informática [29] que gestiona el banco de pruebas y somete los motores a experimentos controlados en donde se definen los parámetros de la prueba. La aplicación controla los estímulos del motor (carga del motor, tiempos de encendido o apagado), monitorea su reacción y se registra todas las variables de interés.

En resumen en esta etapa se acondicionó el laboratorio y se construyó el banco de prueba para motores. Además se programó el software para el controlador del banco como para el usuario.

6.2. Implementación de los experimentos y captura datos

La implementación de los experimentos y captura de datos, implica someter el motor ante las variables independientes y capturar la respuesta del objeto de estudio. Los experimentos realizados sin falta o con faltas inducidas, iniciaron una vez que se cuente con todas las condiciones de seguridad, técnicas y tecnológicas en la bancada de pruebas.

Los experimentos se realizaron de acuerdo al diseño factorial fraccionado, lo cual consiste en someter varios motores de distintas potencias en condiciones




Figura 4: Banco de pruebas implementado. Tomado de [29]

normales de operación y a diferentes porcentajes de carga para determinar las señales características de estos motores sin faltas inducidas, en un ambiente controlado. Estos experimentos requieren de al menos 8000 segundos para que el motor alcance su equilibrio térmico una vez que inicia su funcionamiento.

Se consideran tres factores que influyen directamente con la temperatura interna del motor, que son el voltaje de línea, des balance, sobrecarga térmica (poca ventilación) y niveles de carga. El fraccionamiento corresponde a la operación del motor a 50 %, 75 % y 100 % de carga mecánica en el eje. En total se realizaron más de 60 pruebas distintas al motor. Para el modelo del análisis, se requiere conocimiento de las relaciones de las variables, y se valida mediante la técnica de Análisis Factorial Confirmatorio.

El motor en estudio es de la marca Baldor modelo M3558 de 2hp, 230 V, 60 Hz. Los fallos a los que se somete el motor se realizaron durante su transitorio térmico. El estado estable de la máquina sin fallos asociados se alcanza en 5τ , donde $\tau = R_{th}C_{th}$ según la ecuación (2). Sin embargo, para efectos experimentales se considera que se alcanza el equilibrio térmico cuando dos cambios consecutivos de la temperatura interna, separados por un lapso de cinco minutos, no varía en menos de un grado centigrado, esto es

$$|\theta_t - \theta_{t-5min}| \leq 1^\circ C \quad (37)$$

Para el motor en cuestión, el transitorio térmico experimental se alcanzó aproximadamente en los 8000 segundos bajo el criterio anterior. Durante todo el transitorio térmico se somete el motor a una condición anormal, ya sea subvoltaje, desbalance o un cobertor que simula poca de ventilación, dichas condiciones se denominan fallos tipo uno, dos o tres, respectivamente, la tabla 1 muestra la descripción de los mismos.

Tabla 1: Resumen de condiciones de fallo al 100 % de carga

Fallo	Carga	Voltaje (V)	Desbalance	Cobertor	Nomen.
Sin Fallo	100 %	230	<1 %	No	C100
Tipo 1	100 %	200	<1 %	No	C100V115 ³
Tipo 2	100 %	230	3 %	No	C100D3
Tipo 3	100 %	230	<1 %	Sí	C100Cobertor

De forma similar a las pruebas realizadas con un 100 % de carga, se realizaron pruebas con cargas de 75 % y 50 %. En el código de la prueba se sustituye el término C100 por C75 y C50, según corresponda.

6.3. Análisis de datos y desarrollo del modelo

El análisis de datos tiene como fin el desarrollo de un modelo del comportamiento del motor. En esta sección el proyecto realizó lo siguiente:

- Identificación de los parámetros del un sistema de dos ecuaciones diferenciales con algoritmos genéticos, evolutivos y abejas [7, 23, 30] y apéndice 2, primer artículo en proceso).
- Se propuso un nuevo modelo térmico ampliado, que utiliza 8 ecuaciones diferenciales que representan el comportamiento térmico del motor (ver Apéndice 3, informe 1).
- Se propusieron cinco índices basados en potencia que permiten detectar y diagnosticar el fallo (ver ecuaciones (33) y apéndice 1).
- Se realizaron análisis de variabilidad de los índices y los los resultados fueron confirmados con mapas auto-organizados.

Se incorporó al software desarrollado, el cálculo de los cinco índices en tiempo real. Los índices propuestos aparecen en las ecuaciones (33) y la interfaz gráfica se muestra en la figura 5. Cada segundo se publica la media móvil de los últimos diez valores con la finalidad de suavizar la curvas. El código LabVIEW del cálculo de los índices se muestra en la figura 6. Cuando la prueba finaliza, la aplicación guarda, en archivo de texto, todas las variables eléctricas, mecánicas y los índices propuestos. Así, el archivo contiene los índices calculados en cada segundo durante la prueba.

Con la finalidad de analizar y detectar similitudes entre el comportamiento de los cinco índices definidos en la sección , se entrenó un SOM de 4×4 neuronas, con una tasa de aprendizaje $\alpha = 0,02$ y desviación estándar $\sigma_{\Lambda} = 0,45$, tomando




Figura 5: Interfaz gráfica de los índices en tiempo real

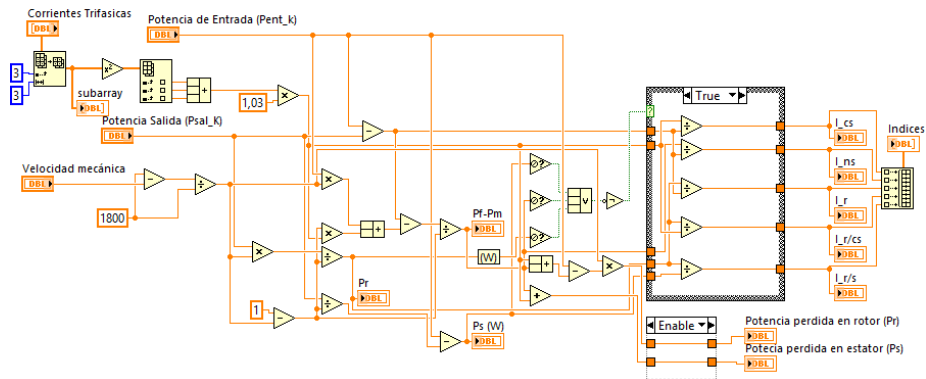


Figura 6: Interfaz de índices en LabVIEW

como entradas los valores de los cinco índices en para las pruebas definidas en la tabla 1.

Siguiendo los resultados obtenidos por medio del SOM para el caso de pruebas al 100 % de carga, se realizó un análisis de los índices por tipo de fallo, de manera independiente, y además se generalizó para pruebas al 75 % y al 50 % de carga. Con el objetivo de validar la agrupación y selección de índices realizada en la sección 4.2.1. y además analizar la variación de los mismos por tipo de prueba (100 %, 75 % y 50 % de carga) y por tipo de fallo (condiciones normales del motor, subvoltaje, desbalance y cobertor)

6.4. Desarrollo del prototipo de SEMAT

Se realizó un prototipo de SEMAT basado en redes neuronales y los índices para los casos experimentales realizados al motor. La red programada en Matlab permite diagnosticar fallos por subvoltajes, desbalances y sobrecargas térmicas para una carga de 100 %.

6.4.1. Clasificador basado en red neuronal

El núcleo del prototipo SEMAT se basó en una red neuronal artificial (RNA) tipo “feed-forward” para decidir si un motor eléctrico presenta alguno de los tres tipos de fallos descritos en la tabla 1 o si se encuentra en funcionamiento normal. La red posee diez entradas distribuidas de la siguiente forma: cinco entradas una para cada índice calculado en un instante específico y las otras cinco entradas para los valores anteriores a las muestras actuales. La red posee una capa oculta de diez neuronas y una capa de salida con cuatro neuronas, una por cada fallo más la salida para el funcionamiento normal. Cada una de las neuronas son idénticas y poseen el funcionamiento de la ecuación (34). Las neuronas de la capa oculta se definieron con la siguiente regla heurística

$$Neuronas \geq \frac{N_e + N_s}{2} \quad (38)$$

donde N_e y N_s representa cantidad de entradas y salidas respectivamente. Se definieron diez neuronas ocultas con el fin de incrementar la exactitud y disminuir el error cuadrático medio. La figura 7 muestra la descripción anterior, los rombos representan los puertos de entrada y el término Z^{-1} indica que esa entrada específica ingresa la muestra anterior del *dataset*, \mathbf{W}_1 representa la matriz de pesos de la capa oculta, esta matriz posee dimensión 10×10 y la matriz de pesos de las neuronas de salida se representa como \mathbf{W}_2 y posee una dimensión de 4×10 . Los pesos de las matrices se puestran en el apéndice 3, informe 3. La salida vectorial \mathbf{F} de la red neuronal queda descrita por la ecuación 39.

$$\mathbf{F} = Tansig(\mathbf{W}_2 \cdot Tansig(\mathbf{W}_1 \cdot \mathbf{I} + \mathbf{b}_1) + \mathbf{b}_2) \quad (39)$$

donde \mathbf{I} es el vector de entradas, \mathbf{b}_1 es el vector de bias de las neuronas de la capa oculta de tamaño 10×1 y \mathbf{b}_2 es el bias de las neuronas de la capa de salida que posee un tamaño 4×1 .

6.4.2. Entrenamiento de la red

A fin de ajustar los pesos almacenados en las matrices \mathbf{W}_1 , \mathbf{W}_2 y de los vectores \mathbf{b}_1 y \mathbf{b}_2 , se realizaron varios entrenamientos supervisados de la red. El mejor resultado se logró con el algoritmo Levenberg–Marquardt con aprendizaje basado en gradiente descendente y momento. La tasa de aprendizaje usada fue de 0,01 y la constante del momento usada fue de 0,9.




Figura 7: RNA para clasificación de fallos de un motor eléctrico

Tal y como se mencionó, el motor en estudio se expuso a los fallos descritos en la tabla 1 y se almacenaron en cada segundo, los cinco índices definidos en la sección 33. El fallo a que se somete el motor está presente durante el transitorio térmico.

Para construir el conjunto de datos de prueba (*dataset*), que posee más de 36000 registros, se unificaron las tres pruebas y la prueba en funcionamiento sin fallo. Posteriormente, se muestreó de forma uniforme cada 180 muestras y se construyó el *dataset* definitivo que posee 200 registros, cada 50 registros corresponde a una prueba específica. Es importante señalar que los 50 registros calculan los índices en distintos instantes del transitorio térmico del motor.

Con la arquitectura de la red neuronal y el *dataset* definitivo se procedió, primeramente, a realizar el entrenamiento supervisado con el algoritmo de retropropagación. La retropropagación es una técnica en la que la red es entrenada con un conjunto de entradas y salidas conocidas y para cada iteración del algoritmo, los pesos de las matrices \mathbf{W} y \mathbf{b} son auto ajustados, con el fin de minimizar el error entre la salida actual y su valor esperado. Este ajuste se aplica desde las capas de salida hasta las capas de entrada, de ahí el nombre de retropropagación. Para el presente trabajo este algoritmo no brindó los resultados esperados dado que el error cuadrático medio presentó valores alrededor de 0,22, considerado alto por los autores. Por esta razón se optó posteriormente en utilizar el algoritmo Levenberg–Marquardt que se utiliza para minimizar funciones por mínimos cuadrados no lineales [26]. La figura 8 muestra la gráfica de

error cuadrático medio (mse) versus la cantidad de entrenamientos completos con el *dataset* definitivo. Se observa un mse de 0,03197 en veintiocho *epochs*.




Figura 8: Error cuadrático medio vs entrenamiento y validación

6.5. Implementación y pruebas de campo

Los sistemas comerciales para detección de fallas requieren de un experto para realizar el diagnóstico del problema, en este caso, SEMAT realiza detección y diagnóstico de fallos con los datos capturados del motor.

Se realizaron comparaciones simuladas entre el prototipo de SEMAT y el equipo comercial Explorer 4000 de SKF.

7. Resultados y discusión de resultados

7.1. Cumplimiento de objetivos

El objetivo específico N 1, donde se requiere establecer las condiciones de experimentación para obtener los modelos térmicos en motores eléctricos de hasta 5 hp, se indica como el principal producto esperado que evidencie el cumplimiento del objetivo, la bancada de pruebas y las variables que se puede medir. En el apéndice 1, trabajos publicados y presentados, artículos expuestos en LACCEI 2014 y 2015, describe detalladamente la bancada de pruebas construida para tal efecto.

Los objetivos específicos N2 y N3, tratan de la caracterización de las señales del comportamiento del motor en operación normal y cuando el motor es sometido a faldas inducidas. El producto esperada consiste en un conjunto de archivos de cada una de las pruebas realizadas que poseen todas las variables medidas y calculadas. En el artículo Valoración de Índices Basados en la Pérdida

de Potencia para la Detección de Faltas en un Motor Eléctrico (CIBIM2017), describe las distintas pruebas realizadas al motor, tanto en operación normal como las faltas inducidas, las cuales fueron necesarias para la construcción de la red neuronal. El objetivo N4 no se logró alcanzar en su totalidad debido a la complejidad del modelo térmico empleado que representada dificultad matemática/computacional que requería mayor tiempo para su análisis, el cual no estaba contemplado. Este se detalla en la sección 7.4.1 del informe.

7.2. Resultado del modelo térmico

Para analizar el comportamiento de los parámetros y de las temperaturas aproximadas del estator y rotor, ante diferentes condiciones y por medio de distintos métodos de optimización, se minimiza el error cuadrático medio definido en (13) por medio de ABC y DE, en los tres conjuntos de pruebas definidos, para identificar cada una de las pruebas se utilizan los códigos C50, C75, C100, Cobertor, V115, D3 y D1, según corresponda (ver tabla 1).

En la tabla 2 se muestran los parámetros obtenidos en todas las pruebas realizadas, según corresponda. Además, se muestra en cada caso el error cuadrático medio alcanzado y el tiempo, en segundos (seg), consumido durante cada ejecución, tanto para el método ABC como para el DE se realizaron siempre 10000 iteraciones.

Analizando y comparando los resultados de la tabla 2 con las gráficas de ajuste de las temperaturas del estator y del rotor a partir de los parámetros del modelo térmico propuesto (ver Apéndice 2, primer artículo en proceso), según corresponda, es posible observar que:

- en algunos casos no se logra alcanzar un error aceptable.
- a pesar de un error aceptable en otros casos, se obtienen algunos valores de los parámetros sin sentido físico, como lo son capacitancias negativas.
- no hay un comportamiento constante, esperado, entre los valores de los parámetros obtenidos con distintos métodos optimización y entre las distintas pruebas realizadas.

lo que nos lleva a pensar que el optimizador se está quedando atrapado en distintos óptimos locales, imposibilitando la obtención de la solución global esperada por medio del modelo térmico.

Prueba	$C_r(ABC)$	$C_r(ABC)$	$G_r(ABC)$	$G_r(ABC)$	$G_r(ABC)$	$Seg(ABC)$	$C_r(DE)$	$C_r(DE)$	$G_r(DE)$	$G_r(DE)$	$Seg(DE)$
C50D1090616	304.4060	7351.1353	0.0982	4.5963	0.3761	0.1858	4910.8505	0.0000	26.7982	38.6562	12.8130
C50D1090616	205.2343	7289.3058	0.0123	4.6296	0.8866	0.2066	68.2037	0.0000	-27.1155	37.7305	0.2104
C50D1230816	345.2335	8386.0741	0.0724	5.3916	0.0457	1.2693	551.9735	0.0000	-13.8820	21.9362	12.7370
C50D3240816	0.0000	8356.0741	0.1706	5.1118	0.0433	9.2083	0.0000	12738.7459	-14.3825	8.0407	14.423
C50D3300816	179.9390	6970.2236	0.0000	4.9726	1.0842	2.1766	4358.8016	0.0000	-14.4675	23.0494	12.8390
C50D3310816	219.6418	7645.4706	0.0000	4.9516	1.0415	1.5240	4827.4287	0.0000	-559.5193	709.9562	1.8842
C50D1V11501116	498.1428	6192.4789	0.0000	4.9715	1.7096	0.1176	0.0000	6970.4548	-7.2260	13.3521	12.7937
C50D1V115261016	496.8256	6203.2686	0.1121	4.2099	0.7987	0.1176	3978.9320	54.9733	-128.2033	174.8739	12.8630
C50D1V115270916	634.0673	4751.2076	0.0460	5.3110	0.9360	0.8508	3738.9355	0.0000	-3.2316	9.4737	0.1103
C50D1V115280916	0.0000	7895.5081	0.2975	4.8136	0.0786	13.9670	0.0000	13330.4600	-37.2175	61.9287	12.9499
C75D1060616	676.8773	6722.5513	0.1183	4.1115	1.0569	0.5224	4888.6604	0.0000	-10.5084	17.6724	12.5564
C75D1100816	690.6473	8385.9510	0.0000	4.5703	1.6743	0.3568	5697.5522	8449.2121	-17.155	26.484	0.2668
C75D1170816	696.6439	7385.7541	0.0000	4.5304	1.6723	0.2598	30.7532	0.0000	-156.3273	159.9886	13.1259
C75D1V230160816	696.6438	8383.9560	0.0000	4.5705	1.6743	0.3568	5679.4863	0.0000	-16.5226	25.7089	0.2667
C75D1V230170816	696.6439	7385.7541	0.0000	4.5304	1.6723	0.2598	5334.4983	8.8955	-28.447	39.8763	12.9172
C75D1V115130816	1045.5636	6419.3112	0.0000	4.5272	2.4607	0.0977	1213.6779	6613.212	-41.4100	22.3738	12.9434
C75D1V115140916	893.9549	6534.9229	0.0000	4.5246	2.2324	7.5676	4858.8805	0.0000	-18.6293	28.1438	12.8934
C75D1Cobertor191016	2292.8720	6312.4277	0.1043	4.4518	0.0000	2206.2509	2416.8245	8028.3752	-85.18439	1090.0212	13.0835
C100D1090816	1036.5821	7230.3321	0.2047	3.8914	1.3188	1.1840	5432.5292	0.0000	-9.3944	16.1288	13.1137
C100D1100816	1352.7135	6324.0926	0.4286	3.4878	0.7069	1.3144	5598.2444	0.0000	-4.3949	10.1868	0.4888
C100D1200616	991.0357	7085.4516	0.0000	3.9341	2.1060	1.8938	4862.3376	0.0000	-10.9427	18.4234	13.0267
C100D30401016	1033.1351	6412.7535	0.1306	4.2260	1.8153	0.1111	1690.2363	5496.7148	-17.7138	10.2737	1.2868
C100D4021116	1191.2173	5514.5069	0.2703	3.8393	0.6069	0.1997	4378.9590	304.5315	-15.7563	24.3243	0.1613
C100D1V115210916	1443.8453	5086.5362	0.0000	3.9680	2.9692	0.1453	4642.5705	0.0000	-143.6488	188.3879	0.1674
C100D1Cobertor060916	1283.8446	6365.9285	0.0000	3.9616	2.3464	1.2008	3153.7022	3981.4309	-5.4192	10.8409	0.4931
C100D1Cobertor070916	1393.8822	6157.2810	0.0000	4.1363	2.4210	1.2795	5302.9871	0.0000	-1.3298	18.0009	13.3150
C100D1Cobertor170616	1393.2684	6232.0663	0.2391	3.4750	0.9873	0.5121	5302.9871	0.0000	-7.3319	13.0954	1.3869
C100D1Cobertor170616	1068.6106	6644.9930	0.4202	3.7335	0.4950	0.5193	5380.9066	0.0000	-34.3174	16.6751	0.3996
C100D1Cobertor121016	936.6124	6841.6641	0.3140	3.8345	0.6774	0.5344	5278.1819	0.0000	-34.3124	47.6255	13.0174
C100D1V115Cobertor201016	465.1248	5767.6490	0.4109	4.0045	0.6823	3.3984	436.4044	5382.1810	0.0325	4.9524	7.4231
											14.0963

Tabla 2: Parámetros obtenidos por ABC y DE en cada una de las pruebas realizadas

7.3. Resultado del prototipo

La figura 9 muestra los resultados de la RNA con el segundo *dataset* construido. Al igual que el primero, este *dataset* posee 200 registros, y cada 50 muestras corresponde a un tipo de fallo, las primeras 50 muestras pertenecen al fallo tipo uno, los siguientes 50 registros al fallo tipo dos y así sucesivamente. Se señala nuevamente que las 50 muestras para cada prueba realizada poseen un espaciamiento temporal uniforme de 180 segundos. Esto a su vez implica que los cinco índices fueron calculados durante el régimen transitorio de temperatura.




Figura 9: Clasificación de índices

Además se observa en la figura 9 que, con los índices propuestos, la RNA detecta los fallos tipo 1 en cualquier instante del transitorio térmico en que ocurra. Esto concuerda con la primera gráfica de correlación de la figura 10, que muestra la correlación del resultado de la red versus el valor real. Para este caso el valor de correlación es de $R = 0,98889$.

Para la prueba del motor con el fallo inducido tipo dos, este presenta tanto falsos negativos como falsos positivos. Este se ve reflejado en el índice de correlación de resultados versus valores reales que es de $R = 0,8483$. Para las pruebas tipo tres, la RNA no diagnóstica algunos casos de este fallo cuando el motor lo sufre (falso negativo), su índice de correlación es de $0,86592$. Finalmente, cuando la red no presenta fallo la RNA logra determinar la gran mayoría de los casos, el índice de correlación es de $0,93703$.

Los resultados de la RNA muestran que los índices propuestos logran discriminar los fallos inducidos al motor durante su transitorio térmico con 100 % de carga. Es decir estos índices son capaces de operar en régimen transitorio como en régimen estable, lo que permite ser utilizados e implementados en el diagnóstico en tiempo real de los motores eléctricos.

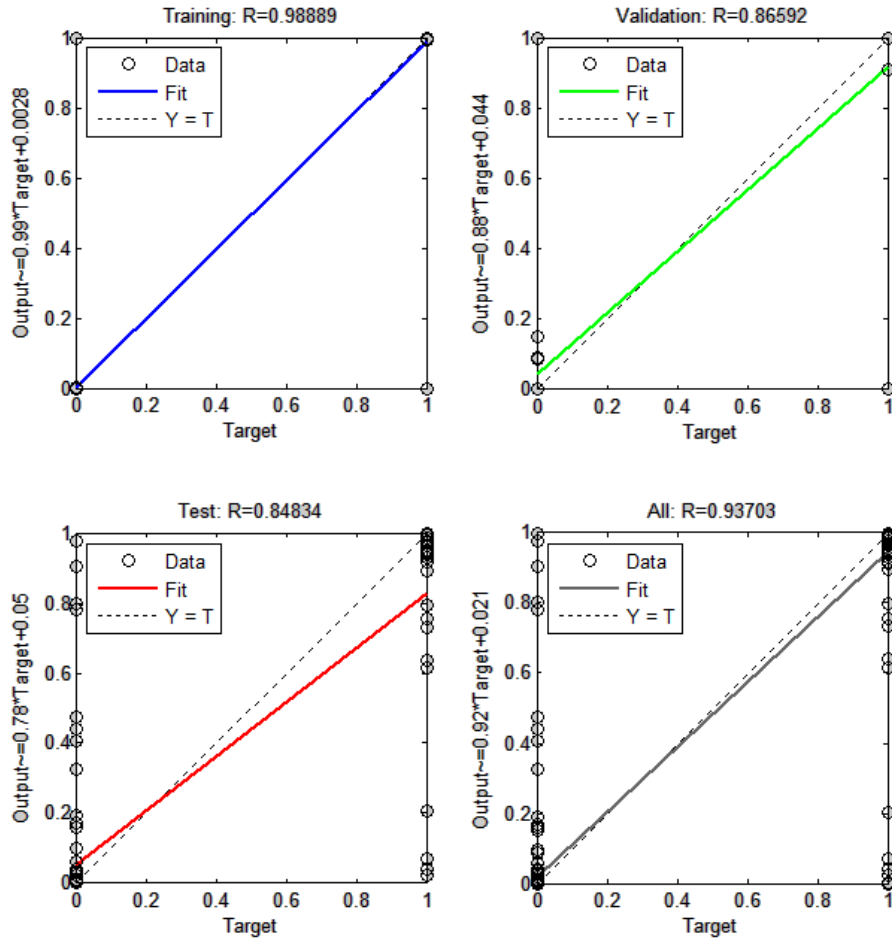


Figura 10: Correlaciones de los resultados de la RNA vs el valor real

Además, los resultados que arroja la RNA pueden ser fácilmente mejorados si se realizan acciones como

- Aumentar al tamaño del **dataset** con pruebas realizadas en otros momentos.
- Aumentar la cantidad de las capas ocultas de la RNA y/o neuronas en cada capa.
- Incrementar las entradas de la RNA retardadas, es decir, agregar entradas con doble retardo Z^{-2} para cada índice.
- Explorar otros algoritmos entrenamiento adaptativos / evolutivos.

- Realizar estudios más detallados variando los parámetros de inicio de los algoritmos.
- Explorar otras topologías de redes neuronales tales como RNA dinámicas, etc.

Por otro lado, la figura 11 muestra el comportamiento de la temperatura del motor ante los tres tipos de fallos indicados anteriormente y la curva de funcionamiento normal, al 100 % de carga. En dicha figura se puede observar que la diferencia entre el comportamiento de cada fallo y el comportamiento normal es mínima, por lo que detectar alguno de esos fallos en el motor no es una tarea sencilla.




Figura 11: Comportamiento térmico del motor con fallos al 100 % de carga

El análisis en la similitud y variación de los índices realizado por medio de SOM indica que es suficiente con tomar solamente tres índices, dado que es posible agruparlos en tres grupos de acuerdo a sus patrones de comportamiento en el tiempo, bajo tres porcentajes de carga (100, 75 y 50) y ante distintos tipos de fallo (subvoltaje, desbalance y cobertor). Así, se toman $I_r - I_{rcs} - I_{rs}$ como índices representativos o significativos para entrenar la RNA, categorizar el comportamiento del motor en el tiempo y detectar algunos de los fallos definidos en la tabla 1. En la figura 12 se muestra el resumen de los índices representativos para todos los casos analizados, se puede notar que dichos índices pueden ser capaces de discriminar no solo por tipo de fallo sino que también por porcentaje de carga.

7.4. Discusión de resultados

Los resultados del proyecto SEMAT son muy amplios y variados, se pueden listar los siguientes productos:




Figura 12: Índices representativos

I_r - I_{rcs} - I_{rs}

- Banco de pruebas para motores de 1hp hasta 5 hp, ubicado en edificio D10 de la Escuela de Ingeniería Electromecánica.
- Aplicación informática para la adquisición de datos en tiempo real, ver [29] y apéndice 4.
- Bases de datos con los registros de más de 60 pruebas distintas en motores de 2 hp. Las pruebas son realizadas bajo diseño factorial.
- Desarrollo de algoritmos basados en varios tipos de heurísticas para la identificación de parámetros de sistemas de ecuaciones diferenciales [7, 23, 30].
- Modelo térmico general para el motor (ver Apéndice 3, informe 1).
- Nuevo método de detección de fallos en motores basados en índices de pérdidas de potencias (ver Apéndice 1, artículo presentados al CIBIM 2017).
- Método para cálculo de potencias en tiempo real.
- Prototipo de sistema experto basado en redes neuronales (ver Apéndice 1, artículo presentado a Tecnología en Marcha 2017).

A continuación se discuten resultados del proyecto y limitaciones de los mismos.

7.4.1. Escalamiento entre modelos

El proyecto SEMAT realizó estudios de modelos térmicos, tal y como se muestra en el trabajo publicado en [23] llamado “Algoritmo bioinspirado aplicado a la estimación de los parámetros de un modelo térmico para un motor trifásico de inducción” (ver apéndice 1). En ese trabajo se presenta el modelo térmico utilizado, dicho modelo predice de forma correcta la temperatura del rotor y como se muestra posteriormente en [7] los parámetros fueron correctamente identificados para 100 % de la carga del motor. Dada la poca cantidad de nodos del modelo este no permite ser utilizado para la detección de fallos, por lo que se propuso un modelo más complejo que represente el comportamiento dinámico de los distintos puntos del motor. Este modelo se presenta en el apéndice 3 llamado “Modelo térmico general”, el cual predice la temperatura en distintos puntos de la máquina, sin embargo la solución matemática para la identificación de los parámetros de dicho modelo, representó un reto matemático/computacional que a la fecha los matemáticos G. Figuerroa-Mata y C. Calderón-Arce están tratando de resolver. Además, se procedió a generalizar las pruebas y resultados obtenidos en [7] para la determinación de parámetros del modelo térmico, en los casos al 50 % y al 75 % de carga, con y sin fallos inducidos, sin embargo no se obtuvieron los resultados esperados. El sistema presenta soluciones sin significado físico en algunos casos, esto se explica debido a que la función objetivo a minimizar posee muchos mínimos locales, por lo que el algoritmo no logró identificar el global y por lo tanto no fue posible encontrar la solución real (ver Apéndice 2, primer artículo en proceso).

Ante esta problemática se decidió valorar la escalabilidad del modelo ante distintos fallos con distintas condiciones de operación. Los resultados mostraron que no hay convergencia en los valores de los parámetros encontrados, esto significa que los parámetros del modelo cambia según los fallos. Dado los resultados mostrados, se analizó la razón de la variación y se determinó que el modelo utiliza las pérdidas del motor que son altamente dependientes del tipo de fallo. Esto implica que los modelos térmicos estudiados no son aptos para la identificación de fallos cuando hay variación de cargas.

A partir del hallazgo de la dependencia entre fallos y pérdidas de potencia, se estableció una nueva estrategia de detección de fallos basados en índices que relacionan potencias. Los índices definidos en (33) serán publicados en los trabajos en el CIBIM 2017 y Tecnología en marcha 2018. En la sección 6.4 demuestra su uso para la detección de fallos ante distintas condiciones de carga, por lo que técnicas de detección basadas en índices son escalables en el sentido de distintos tipos de cargas. También se puede decir que los índices son escalables a otras potencias y marcas, en el sentido que no son exclusivas a una potencia o marca particular. Se destaca que el proyecto SEMAT aporta una nueva técnica de diagnóstico basada en Índices de potencias que puede ser utilizada en cualquier motor trifásico de inducción.

7.4.2. Integrar un sistema de razonamiento basado en casos parametrizable para diagnosticar los fallos en los motores

El motor en estudio se le realizaron 60 casos, entiéndase por caso, una prueba controlada donde se varía al menor de los parámetros de operación del motor. Los parámetros que varían son el voltaje, el desbalance, la carga, sobrecarga térmica. Para cada uno de los casos generaron los índices basados en potencias con la finalidad de realizar el diagnóstico. El sistema de razonamiento se basó en una red neuronal tipo “feed-forward” en que se alimenta con los índices para cada caso/prueba. En la sección 6.4 y en el apéndice 1 se indica la arquitectura de la red utilizada, y las tasas de aprendizaje y de momento del algoritmo de aprendizaje. El tiempo asignado sobre las corridas se estimó basados en las necesidades de obtención de los datos de temperatura, requeridos para desarrollar tanto el modelo ideal como los modelos con falta y poder alcanzar oportunamente las conclusiones sobre los efectos de la temperatura en el motor. Esto significa que los tiempos para correr el modelo ideal sin falta significan al menos 2.5 horas de corrida, para el caso de corridas con falta significan al menos 3 horas de corrida. Adicionalmente para cada corrida se deben incluir tiempos de enfriamiento del motor de al menos 3 horas con ventilación forzada con el fin de llevar el motor a una condición de temperatura ambiente e iniciar la siguiente corrida. Por lo tanto y considerando las limitaciones de tiempo institucionales, no es posible realizar más de 2 corridas en un solo día -en el mejor de los casos-, ya que se pueden presentar variables como pérdida de señal de red, variaciones del voltaje y ciclos imprevistos donde el software deja de correr y se detiene repentinamente la prueba.

Por otra parte, al aplicar los conceptos de diseño de experimentos sobre el proyecto se identificaron 3 factores críticos descritos como faltas en el motor, ellos son: Subvoltaje en la red eléctrica, falla en el ventilador del motor y desbalance de los voltajes de fase. Esto condujo a un diseño factorial empleando por lo tanto los 3 factores en mención, aplicados a un solo motor y con 2 réplicas. Como decisión adicional se definió que alguno de los factores fuera fijo (Bloqueo) para establecer dos de ellos como críticos en dos niveles categóricos y no numéricos. Esto condujo a realizar para un solo motor 24 corridas con un desempeño semanal de 2 corridas por semana a partir del establecimiento definitivo de la operatividad del banco de pruebas.

7.4.3. Desarrollo de un paquete de simulación basado en un modelo térmico

A partir de los cambios realizados, la simulación se realizó con base en índices de potencias y no en modelos térmicos. El proyecto SEMAT posee una red neuronal que permite realizar simulaciones de la detección de fallos. Esta red se realizó en Matlab, la cual puede detectar distintos tipos de fallos de forma simulada. Se requiere mayor entrenamiento a la red, para detectar fallos en otros motores o marcas. Comparar la detección de las faltas empleando prototipo de SEMAT y equipo comercial. La comparación del sistema propuesto basado

en redes neuronales y el equipo comercial Explorer 4000 arroja los siguientes resultados:

Tabla 3: My caption

Condiciones de operación	Prototipo SEMAT (Red Neuronal)	Sistema Comercial (Explorer 4000)
Subvoltaje	<i>Detecta</i>	<i>Detecta</i>
Desbalances 1 %, 3 %, 4 %	<i>Detecta</i>	<i>Detecta</i>
Sobrecarga térmica	<i>Detecta</i>	<i>No Detecta</i>
Variación carga (100, 75 50) %	<i>Detecta</i>	<i>Detecta</i>

De la tabla anterior se observa que los índices de operación detectan la sobrecarga térmica, algo que el equipo comercial que posee la institución no lo logra. Es importante señalar que este tipo de afectación son los que más repercuten en los motores en nuestro país de acuerdo a estudios previos realizados por los investigadores Guerrero y Gómez.

8. Conclusiones

Es importante señalar que antes del proyecto SEMAT solamente el Instituto Costarricense de Electricidad poseía un laboratorio para la prueba de motores en el país. Gracias a este proyecto el TEC construyó un nuevo laboratorio para la prueba de motores de potencias por debajo de 5 hp.

El desarrollo del banco de pruebas fue realizado por los investigadores, es decir el “know how” permanece en la institución. Esto permite que el TEC cuente con laboratorios a un costo mucho menor, por ejemplo solamente la aplicación informática desarrollada para la captura de datos y control de motor posee un costo de \$50000, monto superior al presupuesto del proyecto.

Se realizaron más de 60 pruebas (ver apéndice 4) en motores basados en un diseño de experimentos factorial. Se realizaron pruebas tanto con fallas como sin fallos en el motor, variando un factor a la vez. Cada caso generó un conjunto de datos que fueron utilizados para el cálculos de los modelos térmicos y para el cálculo de los índices y sus estudios de variabilidad.

Se utilizaron distintos tipos de heurísticas para ajustar los modelos a distintos casos/experimentos. Los resultados no convergen cuando la carga cambia (escalabilidad), la variabilidad en los parámetros obtenidos de los modelos térmicos no permitió la construcción del sistema de inferencia para SEMAT, por lo que se exploró otras opciones (índices).

El proyecto SEMAT probó una nueva técnica de diagnóstico basada en índices y valoró su escalabilidad con distintos niveles de carga. Los cinco índices propuestos están basados en las pérdidas de motor con la intensidad de diag-

nosticar fallos específicos en la máquina. Se realizó un análisis de sensibilidad para observar si los índices son capaces de diagnosticar entre distintos fallos. Se requiere mayor análisis del tema, pero se vislumbra que los índices en conjunto pueden mapear distintos fallos que afectan la máquina.

La viabilidad de utilizar los índices, para constituir un sistema experto que diagnostique fallos en tiempo real, se ha demostrado utilizando una red neuronal artificial entrenada con los índices calculados en distintos instantes del régimen transitorio. Esto permite que cuando un fallo particular aparezca, ya sea en régimen transitorio o estable, el sistema con pocas muestras es capaz de determinar el tipo de fallo que afecta al motor. Adicionalmente se determinó que el sistema experto basado en índices puede diagnosticar sobrecargas térmica, lo que el sistema de monitoreo de motores Explorer 4000 no realiza.

9. Recomendaciones

- Si se quiere seguir profundizando con el motor de inferencia para la elaboración de un sistema experto basado en los parámetros de los modelos térmicos, se debe buscar nuevos criterios para la definición de funciones objetivo a optimizar, que determinen parámetros más estables y con significado físico.
- Ampliar el *dataset* de entrenamiento de la red neuronal, con los casos al 75 % y 50 % de carga, y así confirmar los resultados de la red con los obtenidos por medio análisis de índices.
- Agilizar los procesos y trámites de logística para la compra de equipo y paquetes computacionales, así como la instalación de las licencias correspondientes.
- Cuando un investigador renuncia a un proyecto, el proyecto se ve amenazado porque los métodos utilizados en el proyecto y los productos esperados fueron escogidos de acuerdo a la experiencia del colaborador. Se recomienda que la VIE brinde mejor acompañamiento y asesoría a los coordinadores de proyectos para que puedan lidiar con este tipo de inconvenientes.

Referencias

- [1] H. Oraee, "A quantitative approach to estimate the life expectancy of motor insulation systems," *IEEE Transactions on Dielectrics and Electrical Insulation*, vol. 7, no. 6, pp. 790–796, 2000.
- [2] P. Pillay and M. Manyase, "Loss of life in induction machines operating with unbalanced supplies," *IEEE Transactions on Energy Conversion*, vol. 21, no. 4, pp. 813–822, 2006.

- [3] G. Kylander, *Thermal modelling of small cage induction motors*. Doctor of philosophy, Chalmers University of Technology, 1995.
- [4] “IEEE Standard Test Procedure for Polyphase Induction Motors and Generators,” *IEEE Std 112-2004 (Revision of IEEE Std 112-1996)*, pp. 1–79, 2004.
- [5] A. Boglietti, A. Cavagnino, M. Lazzari, and M. Pastorelli, “A Simplified Thermal Model for Variable-Speed Self-Cooled Industrial Induction Motor,” *IEEE Transactions on Industry Applications*, vol. 39, no. 4, pp. 945–952, 2003.
- [6] M. Duran and J. Fernandez, “Lumped-Parameter Thermal Model for Induction Machines,” 2004.
- [7] L. D. Murillo-Soto, G. Figueroa-Mata, and O. Guerrero-Castro, “Identificación de parámetros de un modelo térmico para un motor trifásico de inducción usando algoritmos genéticos,” *Revista Tecnología en Marcha*, vol. 29, no. 5, pp. 25–41, 2016.
- [8] Z. Gao, *SENSORLESS STATOR WINDING TEMPERATURE ESTIMATION FOR INDUCTION MACHINES*. PhD thesis, Georgia Institute of Technology, 2006.
- [9] S. E. Zocholl, “Comparing motor thermal models,” in *In 31st Annual Western Protective Relay Conference*, (WA), pp. 1–10, Schiweitzer Engineering Laboratories, Inc., 2004.
- [10] a. L. Shenkman and M. Chertkov, “Experimental method for synthesis of generalized thermal circuit of polyphase induction motors,” *IEEE Transactions on Energy Conversion*, vol. 15, no. 3, pp. 264–268, 2000.
- [11] B. Dutta and S. Chowdhury, “Steady state thermal model of TEFC induction machine,” in *IEEE International Conference on Emerging Technologies and Factory Automation, ETFAPower Electronics, Drives and Energy Systems (PEDES), 2012*, (Bengaluru), pp. 1–6, 2012.
- [12] J. Moreno, F. Hidalgo, and M. Martinez, “Realisation of tests to determine the parameters of the thermal model of an induction machine,” 2001.
- [13] I. Boldea and S. A. Nasar, *The Induction Machine Handbook*. CRC Press, 2002.
- [14] S. B. Lee and T. G. Habetler, “An online stator winding resistance estimation technique for temperature monitoring of line-connected induction machines,” *IEEE Transactions on Industry Applications*, vol. 39, no. 3, pp. 685–694, 2003.

- [15] Z. Gao, T. G. Habetler, R. G. Harley, and R. S. Colby, "An Adaptive Kalman Filtering Approach to Induction Machine Stator Winding Temperature Estimation Based on a Hybrid Thermal Model," *IEEE Industry Applications Conference*, pp. 2–9, 2005.
- [16] K.-r. Cho and J.-k. Seok, "Induction Motor Temperature Estimation Based on High-Frequency Model of Rotor Bar," in *Industry Applications Society Annual Meeting, 2008. IAS '08. IEEE*, no. 1, pp. 1–7, 2008.
- [17] L. M.-S. y Geovanni Figueroa-Mata y Osvaldo Guerrero-Castro, "Identificación de parámetros de un modelo térmico para un motor trifásico de inducción usando algoritmos genéticos," *Revista Tecnológica en Marcha*, vol. 29, no. 5, pp. 25–41, 2016.
- [18] D. Karaboga, B. Gorkemli, C. Ozturk, and N. Karaboga, "A comprehensive survey: artificial bee colony (ABC) algorithm and applications," *Artificial Intelligence Review*, vol. 41, no. 1, pp. 21–57, 2014.
- [19] D. Karaboga and B. Akay, "Artificial Bee Colony (ABC) Algorithm on Training Artificial Neural Networks," in *2007 IEEE 15th Signal Processing and Communications Applications*, 2007.
- [20] D. Karaboga and C. Ozturk, "Fuzzy clustering with artificial bee colony algorithm," *Scientific research and Essays*, vol. 5, no. 14, pp. 1899–1902, 2010.
- [21] K. Kaswan, S. Choudhary, and K. Sharma, "Applications of Artificial Bee Colony Optimization technique: Survey," in *Applications of Artificial Bee Colony Optimization technique: Survey* (IEEE, ed.), (New Delhi), pp. 1660 – 1664, Computing for Sustainable Global Development (INDIACom), 2015 2nd International Conference on, 2015.
- [22] T. Liao, D. Aydın, and T. Stützle, "Artificial bee colonies for continuous optimization: Experimental analysis and improvements," *Swarm Intelligence*, vol. 7, no. 4, pp. 327–356, 2013.
- [23] G. Figueroa-Mata and L. D. Murillo-Soto, "Algoritmo bioinspirado aplicado a la estimación de los parámetros de un modelo térmico para un motor trifásico de inducción," in *12º Congreso iberoamericano de ingeniería mecánica (CIBIM XII)*, (Guayaquil), 2015.
- [24] W. Cao, "Comparison of IEEE 112 and new IEC standard 60034-2-1," *Energy Conversion, IEEE Transactions on*, vol. 24, no. 3, pp. 802–808, 2009.
- [25] R. Lippmann, "An introduction to computing with neural nets," *IEEE Assp magazine*, vol. 4, no. 2, pp. 4–22, 1987.
- [26] S. S. Haykin, S. S. Haykin, S. S. Haykin, and S. S. Haykin, *Neural networks and learning machines*, vol. 3. Pearson Upper Saddle River, NJ, USA:, 2009.

- [27] M. Dorofki, A. H. Elshafie, O. Jaafar, O. A. Karim, and S. Mastura, “Comparison of artificial neural network transfer functions abilities to simulate extreme runoff data,” *International Proceedings of Chemical, Biological and Environmental Engineering*, vol. 33, pp. 39–44, 2012.
- [28] M. M. Van Hulle, *Self-organizing Maps*, pp. 585–622. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012.
- [29] L. D. Murillo-Soto, “Aplicación informática para el monitoreo de variables eléctricas , mecánicas y térmicas en motores trifásicos de inducción,” in *Latin American and Caribbean Conference for Engineering and Technology (LACCEI’2014)*, (Guayaquil), EBSCO, 2014.
- [30] L. D. Murillo-Soto and G. Figueroa-Mata, “Obtención de parámetros de un modelo térmico para un motor trifásico usando algoritmos genéticos,” in *13th LACCEI Annual International Conference*, (Santo Domingo, República Dominicana), pp. 1–2, LACCEI, 2015.

Apéndices

En esta sección se muestran los trabajos publicados en congresos o revistas indexadas. Los congresos a los que se asistió fue el LACCEI 2014, LACCEI 2015, CIBIM 2015 y la revista Tecnología en Marcha.

El congreso LACCEI "Latin American and Caribbean Consortium of Engineering Institutions" posee indexación en EBSCO y los *proceedings* están disponibles en: <http://www.laccei.org/index.php/publications/laccei-proceedings>. El congreso CIBIM es el Congreso Iberoamericano de Ingeniería Mecánica es un evento bi-anual, organizado por la Federación Iberoamericana de Ingeniería Mecánica. Los congresos están disponible en: <https://www.feibim.org/congresos-feibim-es.html-congresos-celebrados>. Específicamente los dos artículos publicados aparecen en:

- Murillo-Soto, L.D. 'Aplicación Informática para el monitoreo de variables eléctricas, mecánicas y térmicas en motores trifásicos de inducción'. Guayaquil. LACCEI, ISBN 978-0-9822896-7-9
<http://www.laccei.org/LACCEI2014-Guayaquil/ExtendedAbstracts/EA026.pdf>
- Murillo-Soto, L.D. Figueroa-Mata, G. 'Obtención de parámetros de un modelo térmico para un motor trifásico usando algoritmos genéticos'. Santo Domingo. LACCEI. 2015, ISBN 978-0-9822896-8-6, ISSN: 2414-6668
<http://www.laccei.org/LACCEI2015-SantoDomingo/ExtendedAbstracts/EA021.pdf>
- Figueroa-Mata, G. Murillo-Soto, L.D. 'Algoritmo bioinspirado aplicado para la estimación de los parámetros de un modelo térmico para un motor trifásico de inducción', Guayaquil. CIBIM. 2015

Luego se publicó en Tecnología en Marcha el trabajo:

- Murillo-Soto, L.D. Figueroa-Mata, G. 'Identificación de parámetros de un modelo térmico para un motor trifásico de inducción usando algoritmos genéticos'. Tecnología en Marcha, vol 29, no 5.

Posterior a los trabajos publicados, se muestran los trabajos presentados a Tecnología en Marcha en este año 2017 y su acuse, así como el trabajo presentado a el congreso CIBIM 2017 con su acuse. En la parte final de los apéndices se muestran los trabajos en proceso, informes internos y registro de las pruebas realizadas.

Aplicación informática para el monitoreo de variables eléctricas, mecánicas y térmicas en motores trifásicos de inducción

Murillo-Soto, Luis Diego

Instituto Tecnológico de Costa Rica, Cartago, Costa Rica, lmurillo@itcr.ac.cr

ABSTRACT

The present paper describes a monitoring software for study electrical and mechanical variables of a three-phase induction motor. This software has been developed and tested at the Institute Technological of Costa Rica, specifically in the School of Electromechanical Engineering. The software application has been developed from the graphical programming paradigm using LabView v12.0. The interface is connected via an Ethernet network to an embedded system type c- RIO 9073 of National Instruments, which controls the on and off switching of the selected motor and acquires signals currents, voltages, torques, angular velocity, temperature of the study object. Additionally, the interface shows the graphs of the instantaneous values of currents and voltages, shows the spectral content, phase angles, input power, output power, efficiency of the machine and temperature. In addition, the software calculates the imbalance of the power network, the harmonic content of voltage and current, calculates the RMS voltage and current values as well as real, reactive and apparent power, power factor, efficiency, etc.

KEY-WORDS:

Testing Bench, Induction motor, LabView, c-RIO 9073, Graphic User Interface.

RESUMEN

En el presente trabajo describe un software para el monitoreo de las variables eléctricas y mecánicas de un motor trifásico de inducción. Dicho software se ha desarrollado y probado en el Instituto Tecnológico de Costa Rica, específicamente en la Escuela de Ingeniería Electromecánica. La aplicación informática ha sido desarrollada desde el paradigma de programación gráfica usando LabView v12.0. La interface se conecta mediante una red Ethernet a un sistema de embebido del tipo c-RIO 9073 de *National Instruments*, el cual controla el encendido y apagado del motor seleccionado y adquiere las señales de corrientes, voltajes, torque, velocidad angular, temperaturas de los devanados y carcasa. Adicionalmente la interface muestra las gráficas de los

valores instantáneos de corrientes y voltajes, muestra el contenido espectral, ángulos de fase, potencias de entrada, potencia de salida, eficiencia de la máquina y temperaturas. Además el software calcula el desbalance de la red, el contenido armónico de voltaje y corrientes, calcula los valores RMS de corriente y voltaje, así como potencias reales, reactivas y aparentes, factor de potencia, eficiencia, etc.

1. INTRODUCCION

Actualmente el Instituto tecnológico de Costa Rica no cuenta con un laboratorio que permita el estudio integral de las variables eléctricas, mecánicas y térmicas de un motor de inducción. El equipamiento existente no poseen las capacidades para consolidar y manipular los datos medidos. Adicionalmente existen proyectos de investigación en ejecución que requieren una plataforma robusta para la medición y captura de los datos, por tanto se ha construido un banco de pruebas para motores trifásicos. El banco de pruebas busca someter el motor eléctrico a experimentos controlados en donde se definen los parámetros de la prueba, se controlan los estímulos del motor, se monitorea su reacción y finalmente se registra, estas cuatro etapas se muestran en la figura 1.

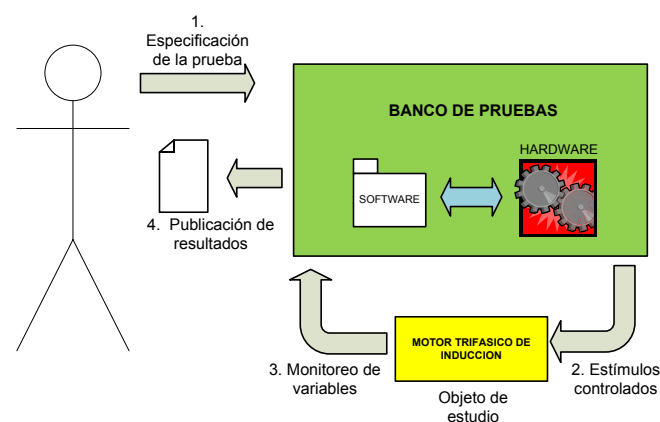


Figura 1. Diseño conceptual del banco de pruebas para la experimentación de motores eléctricos

2. METODOLOGIA

La metodología utilizada tanto para el desarrollo de la interface gráfica se basó en el desarrollo incremental, en donde se destacan cuatro fases cíclicas: especificación del sistema, programación, pruebas de integración de componentes, validación y retroalimentación. La validación del software se realizó por medio de juicio de experto a partir de la funcionalidad del sistema y comparación con equipos calibrados. Por otra parte el software para la tarjeta de adquisición de datos se programó usando una metodología de “Botton to Up”, es decir se programa desde lo más específico es decir el *bitfile* del FPGA y luego se programó el sistema en tiempo real que se comunica con el FPGA y con la PC vía red. La figura 2 muestra las tres capas de software desarrollado, a nivel de PC, a nivel de sistema en tiempo real y a nivel del sistema embebido FPGA.

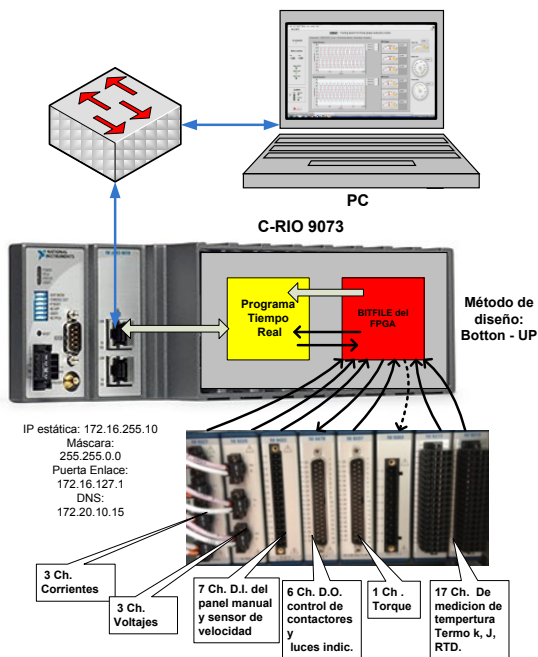


Figura 2. Arquitectura la arquitectura construida, las flechas indican el flujo de los datos

3. CAPACIDADES DEL SOFTWARE

El sistema informático permite controlar vía red el encendido y apagado del motor especificado, y dependiendo del contenido armónico, del desbalance de la red y la condición de sobrecarga el sistema apaga el motor. La interface gráfica permite observar en tiempo real los oscilogramas trifásicos del voltaje y la corriente, así como el espectro trifásico del voltaje y la corriente. También calcula los tres voltajes y corrientes RMS, la potencia real, la potencia reactiva, la potencia aparente, el factor de potencia, el desbalance, la distorsión armónica

total de voltaje y corriente, ángulos de fases, etc. La figura 1 muestra una de las 6 pantallas desarrolladas. En esta pantalla se muestra los osciloscopios de voltaje y corriente trifásica, así como los valores RMS de voltaje y corriente por línea.

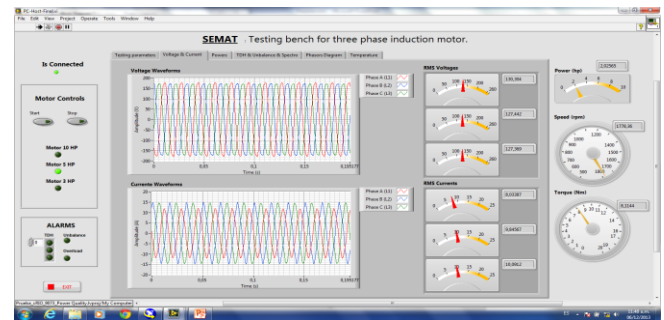


Figura 3. Interface gráfica para voltajes y corrientes.

Además, el sistema brinda las gráficas de la potencia demandada y la gráfica de la eficiencia del motor; adicionalmente la interface brinda graficas de velocidad angular, torque, potencia de salida, eficiencia de la máquina. La interface permite la captura de 17 temperaturas y realiza una gráfica de tendencias. El software genera dos archivos con la información de todas las variables medibles y calculadas. El usuario puede generar en el momento que él lo indique un archivo que registra las señales de voltaje y corriente, esta información permite estudios del fenómeno transitorio del motor. Por otra parte el segundo tipo de archivo crea un registro de 29 variables donde se integran todas las variables medibles eléctricas, mecánicas y térmicas.

4. CONCLUSIÓN

Se desarrollo y probó un sistema informático para el estudio de variables en motores eléctricos, que permite monitorear en forma remota y simultánea múltiples variables eléctricas, mecánicas y térmicas, generar gráficas, vigilar factores de riesgo para el motor, etc.

5. BIBLIOGRAFÍA

- Folea, S. (2011). *LabVIEW: Practical applications and solluction*. Croatia: InTech.
- Lara, J.-R. (2011). *Labview: Entorno gráfico de programación*. Mexico D.F: Marcombo.
- National Instrument. (2013). *NI LabVIEW for CompactRIO: Developer's Guide*. Austin.
- Ponce-Cruz, P. (2010). *Intelligent Control Systems with LabVIEW*. London: Springer-Verlag.

AGRADECIMIENTOS

Se agradece a la Vicerrectora de Investigación por el apoyo brindado al proyecto SEMAT, código VIE 5402-1341-1301.

Obtención de parámetros de un modelo térmico para un motor trifásico usando algoritmos genéticos

Luis D. Murillo-Soto, Magister¹, Geovanni Figueroa-Mata, Magister¹
¹Tecnológico de Costa Rica, Costa Rica, lmurillo@itcr.ac.cr, gfigueroa@itcr.ac.cr

Resumen- Se presenta la metodología para obtener los parámetros térmicos de un motor trifásico de 2 Hp, 230V, 60Hz usando algoritmos genéticos. Se resuelve analíticamente un modelo térmico para usar su solución en la estimación de los parámetros. **Palabras Claves-** Modelo térmico, motor, algoritmo genético.

I. INTRODUCCIÓN

La temperatura de operación en motores trifásicos de inducción es el principal reductor de su vida útil, en [1] se muestran la relación:

$$L_x = L_{100} \cdot 2^{(T_c - T_x)/k} \quad (1)$$

Donde L_x es la nueva estimación de vida proyectada, L_{100} es la proyección de fábrica (20 mil horas), T_x es la nueva temperatura de operación, T_c es la temperatura del tipo de aislamiento y k es una constante según el tipo de aislamiento. Este trabajo muestra la estimación de los parámetros térmicos del motor a partir de datos experimentales y un algoritmo genético con la finalidad de estimar posteriormente el comportamiento térmico de la máquina.

II. MODELO TÉRMICO DEL MOTOR TRIFÁSICO

En [2] se propone el modelo térmico general:

$$C \frac{\partial \theta}{\partial t} = P - G\theta \quad (2)$$

Sin embargo [3] y [4] muestran un modelo simplificado que se adopta y se muestra en (3).

$$\begin{bmatrix} C_s & 0 \\ 0 & C_r \end{bmatrix} \frac{d}{dt} \begin{bmatrix} \theta_s \\ \theta_r \end{bmatrix} = \begin{bmatrix} P_s \\ P_r \end{bmatrix} - \begin{bmatrix} (G_s + G_{sr}) & -G_{sr} \\ -G_{sr} & (G_r + G_{sr}) \end{bmatrix} \begin{bmatrix} \theta_s \\ \theta_r \end{bmatrix} \quad (3)$$

El modelo anterior posee sólo dos nodos llamados θ_s y θ_r que representan la temperatura promedio del estator y del rotor respectivamente. Las pérdidas de potencia del motor se representan como fuentes de calor que elevan las temperaturas internas, la pérdida del estator se llamada P_s y la del rotor P_r . La capacidad del estator y rotor de almacenar calor, es el producto de la masa del componente por el calor específico del material, tanto el estator como el rotor poseen capacitancias térmicas llamadas C_s y C_r . Finalmente las conductancias térmicas entre el estator y el ambiente, entre el rotor y el estator, entre el rotor y el ambiente son G_s, G_{sr}, G_r respectivamente, donde la conductancia es el inverso de la resistencia térmica.

Se solucionó de forma analítica la ecuación (3) y se obtuvo las ecuaciones (4) que modelan la temperatura del estator θ_s y del rotor θ_r en función de los parámetros térmicos.

$$\begin{aligned} \theta_s &= C_1 e^{r_1 t} + C_2 e^{r_2 t} + \frac{E}{B} \\ \theta_r &= C_3 e^{r_1 t} + C_4 e^{r_2 t} + \frac{F}{B} \end{aligned} \quad (4)$$

Donde las constantes de (4) en función de los parámetros son:

$$\begin{aligned} C_1 &= \frac{E(r_2 C_s + G_s + G_{sr}) - F G_{sr}}{B C_s (r_1 - r_2)} & C_2 &= \frac{E(r_1 C_s + G_s + G_{sr}) - F G_{sr}}{B C_s (r_2 - r_1)} \\ C_3 &= \frac{C_1 (r_1 C_s + G_s + G_{sr})}{G_{sr}} & C_4 &= \frac{C_2 (r_2 C_s + G_s + G_{sr})}{G_{sr}} \\ B &= \frac{G_s G_r + G_s G_{sr} + G_r G_{sr}}{C_s C_r} & E &= \frac{G_r P_s + G_{sr} P_s + G_{sr} P_r}{C_s C_r} \\ F &= \frac{G_s P_r + G_{sr} P_r + G_{sr} P_s}{C_s C_r} & r_1, r_2 & \text{son las soluciones de la ecuación característica asociada.} \end{aligned}$$

II. ALGORITMO GENÉTICO

Los algoritmos genéticos son utilizados tradicionalmente para resolver problemas de búsqueda y/o optimización, en los cuales se tiene que determinar la mejor solución de un conjunto de soluciones factibles de gran tamaño. A cada solución factible generada se le asocia un valor llamado aptitud. Este valor cuantifica la calidad de la solución y permite comparar soluciones de la misma generación y/o con soluciones de generaciones anteriores.

El algoritmo genético programado según criterios de [5], da inicio con una población inicial de soluciones factibles, la cual se construye de forma aleatoria. Se evalúa la aptitud de cada individuo de la población y se construye nueva población mediante cruzamiento, mutación y selección. Este proceso se repite hasta que algún criterio de parada sea satisfecho, como se muestra en la figura 1.




Fig. 1 Diagrama de bloques para la identificación del modelo térmico.

III. BANCO DE PRUEBAS Y ADQUISICIÓN DE DATOS

Se diseñó y construyó un banco de pruebas para motores trifásicos que se compone básicamente de un generador de corriente directa de 5 kW y un banco de resistencias de 7 kW. El banco posee tres autotransformadores monofásicos conectados en estrella para provocar bajos y altos voltajes de alimentación así como desbalances. Finalmente poleas y fajas para acoplar mecánicamente el motor al generador tal como se aprecia en la figura 2.

Se desarrolló una solución informática [6] en *LabView* v12.0 que gestiona el banco de pruebas mediante un controlador de tiempo real C-Rio 9073 y somete los motores a experimentos controlados en donde se definen los parámetros de la prueba, se controlan los estímulos del motor (carga del motor, tiempos de encendido o apagado), se monitorea su reacción y finalmente se registran en archivos todas las variables de interés, específicamente voltajes y corrientes trifásicas, torque, velocidad angular y once puntos de temperatura en el motor.




Fig. 2 Imagen parcial del banco de pruebas implementado.

IV. IDENTIFICACIÓN DE PARÁMETROS DEL MODELO

Se estiman los parámetros $G = (G_s, G_r, G_{sr})$ y $C = (C_s, C_r)$ comparando la respuesta θ_s del modelo de referencia basado en la ecuación (4), se toma el incremento de temperatura en el estator $\Delta\theta$ como la diferencia entre las temperaturas medidas del devanado eléctrico θ y el ambiente, $\Delta\theta = \theta - \theta_0$.

El modelo de referencia se alimenta con el vector de pérdidas $P = (P_s, P_r)$, y los vectores de parámetros a estimar $C = (C_s, C_r)$ y $G = (G_s, G_r, G_{sr})$ generados por el algoritmo genético tal como se muestra en la figura 1. Luego se compara su respuesta con las temperaturas medidas del estator, se ajustan de nuevo los parámetros y se realimenta el sistema. El proceso de optimización se detiene cuando no hay cambios significativos en los vectores de parámetros C y G . La función objetivo a optimizar está dada por la función de error cuadrático medio (5), la cual se obtiene restando los datos experimentalmente medidos $\Delta\theta$ y la respuesta del modelo térmico θ_s .

$$\varepsilon = \frac{1}{N} \sum_{i=0}^N (\Delta\theta(t_i) - \theta_s(t_i))^2 \quad (5)$$

Para calcular el vector de pérdidas, primero se calcula la pérdida total como la diferencia entre la potencia eléctrica de entrada menos la potencia mecánica de salida. La potencia obtenida se separa mediante el cálculo de pérdidas del estator, núcleo, mecánica y otras, según la norma IEEE 112 [7]. El vector de pérdidas calculado es $P = [306 \ 60]^T$ Watts, para el motor de 2 hp al 100% de carga.

Si el cambio acumulado en el valor de la función objetivo a lo largo de las generaciones es menor que la tolerancia de funciones 10^{-15} o si se alcanza el número máximo de 100000 generaciones se detiene la búsqueda. Los parámetros encontrados se muestran en la tabla I y ajustan a la temperatura medida del estator como se aprecia en la figura 3.

Símbolo	Valor	Símbolo	Valor
C_r	5561.66 J/°C	G_{sr}	12.36 W/°C
C_s	5129.74 J/°C	Mejor aptitud	0.532
G_r	6.18 W/°C	Aptitud promedio	0.663
G_s	4.19 W/°C		




Fig. 3 Ajuste de temperaturas entre la medida y la estimada.

AGRADECIMIENTO

Se agradece a la Vicerrectora de Investigación por el financiamiento brindado al proyecto SEMAT, código VIE 5402-1341-1301.

REFERENCIAS

- [1] H. Oraee, "A quantitative approach to estimate the life expectancy of motor insulation systems," *IEEE Trans. Dielectr. Electr. Insul.*, vol. 7, no. 6, pp. 790-796, 2000.
- [2] G. Kylander, "Thermal modelling of small cage induction motors," Chalmers University of Technology, 1995.
- [3] M. J. Duran and J. Fernandez, "Lumped-Parameter Thermal Model for Induction Machines," *IEEE Transactions on Energy Conversion*, vol. 19, pp. 791-792, 2004.
- [4] J. F. Moreno, F. P. Hidalgo, and M. D. Martínez, "Realisation of tests to determine the parameters of the thermal model of an induction machine," *IEE Proceedings - Electric Power Applications*, vol. 148, p. 393, 2001.
- [5] E. G. Talbi, *Metaheuristics: From Design to Implementation*. 2009.
- [6] L. D. Murillo-Soto, "Aplicación informática para el monitoreo de variables eléctricas, mecánicas y térmicas en motores trifásicos de inducción," in *Latin American and Caribbean Conference for Engineering and Technology (LACCEI'2014)*, 2014.
- [7] "IEEE Standard Test Procedure for Polyphase Induction Motors and Generators," *IEEE Std 112-2004 (Revision IEEE Std 112-1996)*, 2004.

12º CONGRESSO IBEROAMERICANO DE ENGENHARIA MECANICA

Guayaquil, 10 a 13 de Novembro de 2015

ALGORITMO BIOINSPIRADO APLICADO A LA ESTIMACIÓN DE LOS PARÁMETROS DE UN MODELO TÉRMICO PARA UN MOTOR TRIFÁSICO DE INDUCCIÓN

Geovanni Figueroa-Mata*, Luis Diego Murillo-Soto°

Instituto Tecnológico de Costa Rica, *Escuela de Matemática, °Escuela de Ingeniería Electromecánica
e-mail: *gfigueroa@itcr.ac.cr ; °lmurillo@itcr.ac.cr

RESUMEN

Se propone una variante del algoritmo *Artificial Bee Colony (ABC)* que utiliza un generador de números cuasi-aleatorios de Sobol, para determinar las matrices de capacitancias térmicas \mathbf{C} y de conductancias térmicas \mathbf{G} de un modelo térmico para un motor eléctrico marca Baldor modelo M3558, de 2 hp, 230V, 60 Hz, expresado por la ecuación diferencial $\mathbf{C}\dot{\mathbf{T}} = \mathbf{P} - \mathbf{G}\mathbf{T}$. El vector de potencias disipadas \mathbf{P} se estima según IEEE 112 y el vector de temperaturas \mathbf{T} se obtiene por medio de un banco de pruebas construido para este fin. Dicho banco de pruebas utiliza un sistema de adquisición de datos de tiempo real marca *National Instruments* C-Rio 9073, el cual se programó para capturar por segundo todas las variables térmicas y eléctricas involucradas. La topología propuesta para el modelo térmico del motor posee dos nodos que generan un sistema de ecuaciones diferenciales el cual se resuelve analíticamente. El algoritmo ABC se alimenta con las pérdidas \mathbf{P} estimadas para dicho motor eléctrico, con las temperaturas \mathbf{T} medidas mediante el banco de pruebas y con las temperaturas $\tilde{\mathbf{T}}$ estimadas numéricamente a partir de la solución analítica del sistema de ecuaciones diferenciales, esto con el fin de ir modificando los parámetros \mathbf{C} y \mathbf{G} del modelo propuesto de manera tal que se minimice el error cuadrático medio de la diferencia de temperaturas medidas y estimadas: $\varepsilon = \frac{\|\mathbf{T} - \tilde{\mathbf{T}}\|^2}{\|\mathbf{T}\|}$. El proceso se ejecuta hasta que se cumplan los criterios de ajuste establecidos. Finalmente se validan los parámetros obtenidos con los cálculos experimentales de las distintas resistencias y capacitancias térmicas y con los resultados de un algoritmo genético

PALABRAS CLAVE: Algoritmo ABC, optimización, estimación de parámetros térmicos, motor eléctrico.

INTRODUCCION

Los motores eléctricos de inducción representan la principal fuerza motriz para accionar los sistemas electromecánicos, estimar de forma correcta la temperatura interna de la máquina es una necesidad por las implicaciones que esto tiene sobre la vida útil de la máquina. Los materiales y barnices aislantes del motor se degradan de forma exponencial, por cada 10°C por encima de la temperatura máxima de la clase del aislamiento la vida útil se reduce a la mitad [1],[2].

Se han propuesto algunos modelos para estimar la temperatura interna de un motor. De acuerdo con [3], los modelos de primer orden son rápidos y eficientes, presentan una buena estimación de la temperatura y necesitan solamente el valor de la corriente estatórica, pero esta estimación es un promedio general que no permite determinar los puntos calientes de la máquina. En [4] se realiza una comparación entre distintos tipos de modelos de primer orden, los cuales posee una estructura similar a la ecuación (1).

$$\theta = I^2 R R_{th} \left(1 - e^{\frac{-t}{R_{th} C_{th}}} \right) + \theta_A \quad (1)$$

Donde θ y θ_A son las temperaturas interna y la ambiental respectivamente, el término $I^2 R$ representa la totalidad de pérdidas del motor, R_{th} representa una resistencia térmica equivalente y C_{th} representa la capacitancia térmica del motor.

Por su parte, los modelos térmicos mallados para estados estables permiten predecir la temperatura en zonas específicas de la máquina, con el inconveniente de que la estimación de temperaturas en el transitorio térmico presenta errores de hasta un cien por ciento. Estos modelos en estado estable tales como los que se plantean en [5], [6], [7], obtienen las temperaturas resolviendo sistemas de ecuaciones lineales (2), donde \mathbf{P} es el vector de pérdidas de la máquina, \mathbf{G} es la matriz de conductancias térmicas del motor y $\boldsymbol{\theta}$ es el vector de temperaturas a calcular.

$$\mathbf{P} = \mathbf{G}\boldsymbol{\theta} \quad (2)$$

Los modelos térmicos mallados para estados transitorios son aquellos que pueden predecir la temperatura en un punto específico de la máquina, tanto en régimen transitorio como en estado estable. Estos modelos incorporan un tercer vector a la ecuación (2), el cual se forma al multiplicar una matriz \mathbf{C} que contiene en su diagonal las capacitancias térmicas de la máquina, por un vector que contiene las derivadas de las temperaturas respecto al tiempo $d\theta/dt$, de tal forma que la expresión general está dada por:

$$\mathbf{C} \frac{\partial \boldsymbol{\theta}}{\partial t} = \mathbf{P} - \mathbf{G}\boldsymbol{\theta} \quad (3)$$

Otros modelos más complejos como los que se plantean en [1], [8], [9] representa el estado transitorio. Estos ofrecen una predicción de la temperatura en el respectivo nodo, pero para poderla estimar se requiere conocer los materiales, geometrías, dimensiones y masas para calcular cada conductancia térmica entre los nodos \mathbf{G} y la matriz de capacitancia \mathbf{C} . Adicionalmente se requiere conocer en forma detallada cada una de las pérdidas reales \mathbf{P} de la máquina, para esto es necesario realizar pruebas de laboratorio. Cabe señalar que estos inconvenientes también se presentan en los modelos en estado estable, ecuación (2).

Por otro lado la estimación de temperatura con base en parámetros eléctricos, se divide fundamentalmente en dos esquemas. El primer esquema surge del estándar IEEE 112 [10], en donde se indica que la variación de la temperatura interna provoca variaciones de las resistencias estatóricas y rotóricas del motor en la siguientes proporciones:

$$R_2 = R_1 \frac{\theta_2 + k}{\theta_1 + k} \quad (4)$$

$$\theta_2 = \frac{R_2}{R_1} (\theta_1 + k) - k \quad (5)$$

Donde R_1 representa la resistencia a la temperatura θ_1 , usualmente medida a temperatura ambiente con motor apagado, R_2 la resistencia a la temperatura θ_2 y k es el coeficiente del material conductor, donde para el cobre es 234.5 y para el aluminio es de 225. La ecuación (5) muestra el resultado de despejar la temperatura interna. Para obtener el valor de las resistencias se utilizan dos métodos, el primero calcula la resistencia aplicando la ley de Ohm a la medición del voltaje y corriente continua (CD). El otro método es la medición directa con puente wheatstone doble, mediante un miliohmímetro. Consecuentemente y dado que el punto más caliente de una máquina es el devanado estatórico [11], la medición de la resistencia estatórica es el método más sencillo de estimación de temperaturas.

La desventaja del esquema de medición de la resistencia estatórica es que es invasivo, ya que requiere de equipamiento adicional y desconectar eléctricamente la máquina. Por tal motivo se han venido desarrollando métodos alternativos de obtención de la resistencia estatórica a partir de mediciones eléctricas de voltajes y corrientes, [3],[12],[13] o frecuencias [14]. La idea de estos trabajos es desarrollar equipos en tiempo real que operen en línea con el motor y que realicen los respectivos cálculos de la estimación de temperatura interna. El principal inconveniente de estos métodos es que estiman la temperatura interna del devanado, pero no estiman el

comportamiento de las temperaturas en otras zonas de interés en el motor, tal como la temperatura del núcleo, roles, carcasa, etc.

El presente trabajo propone una forma alternativa de estimar los parámetros térmicos de un motor a partir de datos experimentales y mediante la optimización de los errores vía un algoritmo bioinspirado, esto con el propósito de estimar posteriormente el comportamiento térmico de la máquina. En la sección 2 se hace una descripción del modelo térmico utilizado. La sección 3 describe el banco de pruebas construido para capturar las mediciones de las variables térmicas y eléctricas necesarias. La sección 4 muestra los resultados del cálculo del vector de pérdidas del motor. La sección 5 describe el proceso de estimación de las matrices de capacitancias C y de conductancias G . En la sección 6 se presenta la validación de los resultados obtenidos mediante técnicas alternativas, la sección 7 cierra con las conclusiones.

MODELO TÉRMICO PROPUESTO

El modelo térmico que se utiliza para el motor de estudio, es propuesto en [8] y [9]. Este modelo se construye a partir de la ecuación general (3). El modelo de la de la Figura 1, posee dos nodos llamados θ_s y θ_r que representan la temperatura promedio del estator y del rotor, respectivamente. Por otra parte, la temperatura θ_0 se refiere a la temperatura ambiental. El modelo representa las pérdidas de potencia del motor como fuentes de calor que elevan las temperaturas internas. La fuente del estator es llamada P_s y la del rotor P_r . Los capacitores térmicos C_s y C_r representan la capacidad del estator y rotor de almacenar calor, son el producto de la masa del componente por el calor específico del material.




Figura 1. Modelo térmico de un motor eléctrico de inducción. Adaptado de [8].

Deducción del modelo

A partir la ecuación (3) y del modelo térmico de la figura 1, se obtiene el sistema de ecuaciones diferenciales de primer orden, con sus condiciones iniciales:

$$\begin{bmatrix} C_s & 0 \\ 0 & C_r \end{bmatrix} \begin{bmatrix} \frac{d\theta_s}{dt} \\ \frac{d\theta_r}{dt} \end{bmatrix} = \begin{bmatrix} P_s \\ P_r \end{bmatrix} - \begin{bmatrix} (G_s + G_{sr}) & -G_{sr} \\ -G_{sr} & (G_s + G_{sr}) \end{bmatrix} \begin{bmatrix} \theta_s \\ \theta_r \end{bmatrix} \quad (6)$$

$$\theta(0) = \begin{bmatrix} 0 \\ 0 \end{bmatrix}$$

Las condiciones iniciales indican que el motor se encuentra a temperatura ambiente, es decir, $\theta_s(0) = 0$ y $\theta_r(0) = 0$.

Al resolver de forma analítica el sistema de ecuaciones diferenciales (6) se obtienen las ecuaciones (7) que modelan la temperatura del estator θ_s y del rotor θ_r en función de los parámetros térmicos y el tiempo t .

$$\begin{aligned} \theta_s &= C_1 e^{r_1 t} + C_2 e^{r_2 t} + \frac{E}{B} \\ \theta_r &= C_3 e^{r_1 t} + C_4 e^{r_2 t} + \frac{F}{B} \end{aligned} \quad (7)$$

Donde las constantes en (7) están dadas por:

$$C_1 = \frac{E(r_2 C_s + G_s + G_{sr}) - FG_{sr}}{B C_s(r_1 - r_2)}$$

$$C_3 = \frac{C_1(r_1 C_s + G_s + G_{sr})}{G_{sr}}$$

$$B = \frac{G_s G_r + G_s G_{sr} + G_r G_{sr}}{C_s C_r}$$

$$F = \frac{G_s P_r + G_{sr} P_r + G_{sr} P_s}{C_s C_r}$$

$$C_2 = \frac{E(r_1 C_s + G_s + G_{rs}) - FG_{rs}}{B C_s(r_2 - r_1)}$$

$$C_4 = \frac{C_2(r_2 C_s + G_s + G_{sr})}{G_{sr}}$$

$$E = \frac{G_r P_s + G_{sr} P_s + G_{sr} P_r}{C_s C_r}$$

Donde r_1 , r_2 son las soluciones de la ecuación característica asociada.




Figura 2. Imagen parcial del banco de pruebas implementado. Tomado de [15].

BANCO DE PRUEBAS Y ADQUISICIÓN DE DATOS

Se diseñó y construyó un banco de pruebas para motores trifásicos que se compone básicamente de un generador de corriente directa de 5 kW y un banco de resistencias de 7 kW. El banco posee tres autotransformadores monofásicos conectados en estrella para provocar bajos y altos voltajes de alimentación así como desbalances. Finalmente poleas y fajas para acoplar mecánicamente el motor al generador tal como se aprecia en la Figura 2.

Se desarrolló una solución informática [16] en *LabView* v12.0 que gestiona el banco de pruebas mediante un controlador de tiempo real C-Rio 9073 y somete los motores a experimentos controlados en donde se definen los parámetros de la prueba, se controlan los estímulos del motor (carga del motor, tiempos de encendido o apagado), se monitorea su reacción y finalmente se registran en archivos todas las variables de interés, específicamente voltajes y corrientes trifásicas, torque, velocidad angular y once puntos de temperatura en el motor.

ESTIMACIÓN DEL VECTOR DE PÉRDIDAS

Para calcular el vector de pérdidas, primero se calculó la pérdida total como la diferencia entre la potencia eléctrica de entrada menos la potencia mecánica de salida. La potencia obtenida se separa mediante el cálculo de pérdidas del estator, núcleo, mecánica y otras, según la norma IEEE 112 [10]. El vector de pérdidas así calculado es $\mathbf{P} = [306 \ 60]^T$ Watts, para el motor en estudio al 100% de carga. El detalle de los cálculos puede consultarse en [17].

ESTIMACIÓN DE PARÁMETROS

La estrategia usada para estimar los parámetros $\mathbf{G} = [G_s, G_r, G_{sr}]^T$ y $\mathbf{C} = [C_s, C_r]^T$ es la siguiente: se compara la respuesta θ_s del modelo de referencia basado en la ecuación (7), con el incremento de temperatura en el estator $\Delta\theta$. El incremento $\Delta\theta$ se entiende como la diferencia entre las temperaturas medidas en el devanado eléctrico θ y la temperatura ambiente, $\Delta\theta = \theta - \theta_0$. Los parámetros del modelo de referencia se van ajustando iterativamente de manera tal que la diferencia entre las respuestas de ambos modelos sea mínima, en este sentido, el ajuste de los parámetros es un problema de optimización.

La función de incremento de temperatura en el estator $\Delta\theta = \theta - \theta_0$ se puede estimar con precisión, pues se tiene la temperatura en el devanado y la temperatura ambiente, las cuales han sido medidas cada segundo a lo largo de un período de 2 horas 30 minutos. De esta forma la función objetivo a optimizar está dada por la función de error cuadrático medio $\varepsilon = \frac{1}{N} \sum_{i=0}^N (\Delta\theta(t_i) - \theta_s(t_i))^2$, la cual se obtiene restando los datos experimentalmente medidos $\Delta\theta$ y la respuesta del modelo térmico θ_s .

Debido a la complejidad del problema los métodos clásicos no son la mejor opción y es necesario aplicar otras estrategias de optimización. Para este tipo de problemas se han propuesto y probado con éxito una gran variedad de algoritmos de optimización bioinspirados como: los algoritmos genéticos (**GA**), inspirados en la ley de sobrevivencia del más fuerte; enjambre de partículas (**PS**) inspirado en el comportamiento social de bandadas de pájaros o cardúmenes de peces; colonia de hormigas (**AC**), inspirados en los hábitos alimentarios de colonias de hormigas, y más recientemente el algoritmo bioinspirado *Artificial Bee Colony* (**ABC**) que simula el comportamiento alimentario de los enjambres de abejas [18]. Desde su creación en 2005 este algoritmo ha sido aplicado a la solución de una gran cantidad de problemas de optimización [19],[20],[21] y se han propuesto muchas variantes del mismo [22],[23].

El algoritmo **ABC** es un algoritmo de inteligencia de enjambre que intenta emular el comportamiento de las abejas en cuanto a la búsqueda y explotación de fuentes de alimento. Para esto define una colmena artificial formada por un área de comunicación llamada área de danza y tres tipos de abejas: obreras (en inglés: employed), observadoras (en inglés: onlookers) y exploradoras (en inglés: scouts). El algoritmo **ABC** busca las mejores fuentes de alimento las cuales son valoradas con un número que indica su calidad. Para esto toma en cuenta la cercanía a la colmena, la cantidad de alimento y la facilidad de extraer el alimento.

Las abejas empleadas están asociadas con una fuente de alimento en particular y son las encargadas de explotar dicha fuente de alimento, además, llevan consigo la información de esta fuente de alimento y la comparten con las abejas observadoras, indicando la cercanía y rentabilidad de la fuente.

Las abejas observadoras están esperando en el área de danza de la colmena a que las abejas empleadas les compartan la información sobre las fuentes de alimento para elegir las mejores fuentes que serán explotadas.

Cuando una fuente de alimento se agota se selecciona de forma aleatoria una nueva fuente de alimento para reemplazar la que se agotó. La actividad de explotación la realizan las abejas exploradoras y las empleadas, mientras que la búsqueda de nuevas fuentes para ser explotadas la realizan las abejas observadoras.

Una fuente de alimento representa una solución factible del problema de optimización y la cantidad de alimento de la fuente corresponde a la calidad de la solución (en inglés: fitness).

Los parámetros de entrada del algoritmo **ABC** básico son: el tamaño de la colmena (CS), la dimensión o número de variables del problema (D), el límite de iteraciones antes de abandonar un fuente de alimento ($L = CS \cdot D / 2$), el número de soluciones (SN) y el máximo número de iteraciones (N).

El número de abejas empleadas es usualmente igual al número de fuentes de alimento (soluciones factibles) y se asigna una abeja empleada a cada fuente de alimento. Al llegar a dicha fuente de alimento la abeja calcula una nueva solución a partir de esta (vuela a una fuente de alimento cercana) y conserva la mejor solución. El número de abejas observadoras es también usualmente igual al de abejas empleadas y son asignadas a una fuente de alimento tomando en cuenta la calidad (aptitud) de la fuente. Al igual que las abejas empleadas calculan una nueva solución a partir de su fuente de alimento. Cuando una fuente no mejora después de un cierto número de iteraciones (L) se abandona y se reemplaza por aquella encontrada por una abeja exploradora.

Inicialmente se generan de forma cuasi-aleatoria mediante una secuencia de Sobol SN fuentes de alimento (soluciones factibles) y se evalúa su calidad. Esto se hace así con el fin de evitar el agrupamiento de soluciones factibles y cubrir de manera más uniforme el espacio solución. Luego se ejecuta N veces el siguiente ciclo de instrucciones: se calculan nuevas soluciones candidatas (nuevas fuentes de alimento) mediante la ecuación:

$$v_{ij} = x_{ij} + \phi(x_{ij} - x_{kj}) \quad (8)$$

Aquí, ϕ es un valor aleatorio con distribución uniforme en el intervalo $[-1,1]$, k es cualquiera de las fuentes diferente de la fuente i , y $j \in \{1,2, \dots, D\}$. Se evalúan las soluciones encontradas y se comparan con la solución actual y se guarda la mejor de las dos. Luego se envían las abejas observadoras a las fuentes de alimento de forma que cada abeja observadora elige una fuente de alimento con cierta probabilidad calculada mediante la ecuación:

$$P_i = \frac{fit_i}{\sum_{i=1}^{SN} fit_i} \quad (9)$$

Donde

$$fit_i = \begin{cases} \frac{1}{1 + f_i} & \text{Si } f_i \geq 0 \\ 1 + |f_i| & \text{Si } f_i < 0 \end{cases}$$

Luego se calculan nuevas soluciones candidatas con la fórmula (8) para las abejas observadoras y se comparan con la solución actual guardando la mejor de las dos. Se observa si existen fuentes agotadas, esto se hace comparando el valor límite de la solución con el valor límite establecido (L), de ser el caso se reemplaza la fuente con una nueva fuente de las encontradas por las abejas exploradoras mediante la ecuación:

$$x_{ij} = \min_j + \text{rand}(0,1) * \max_j - \min_j \quad (10)$$

Donde \min_j y \max_j son las cotas inferior y superior del parámetro j .

Los pasos anteriores se repiten N veces y el algoritmo termina guardando la mejor solución encontrada. En la Figura 3 se muestra el pseudo-código de algoritmo ABC.

Entrada: Parámetros del algoritmo: CS, D, SN, N
Salida: Individuo mejor adaptado (mejor solución)
1: Generar la población inicial de soluciones $x_{i0}, i = 1, 2, \dots, SN$ 2: Evaluar la aptitud de población 3: $j = 1$ 4: Repetir 5: Producir nuevas soluciones v_{ij} para las abejas empleadas y evaluarlas 6: Guardar la mejor solución entre la actual y las candidatas 7: Seleccionar las soluciones que serán visitadas por las abejas observadoras 8: Producir nuevas soluciones v_{ij} para las abejas observadores y evaluarlas 9: Guardar la mejor solución entre la actual y las candidatas 10: Determinar si existen fuentes abandonadas y reemplazarlas usando una abeja exploradora 11: Guardar la mejor solución encontrada hasta el momento 12: $j = j + 1$ 13: Hasta $j = N$ 14: Fin

Figura 3. Algoritmo ABC básico.

La Figura 4 muestra un diagrama de bloques donde se ilustra el proceso de estimación de parámetros. El modelo de referencia se alimenta con el vector de pérdidas $\mathbf{P} = [P_s, P_r]^T$ y los vectores de parámetros a estimar $\mathbf{C} = [C_s, C_r]^T$ y $\mathbf{G} = [G_s, G_r, G_{sr}]^T$ generados por el algoritmo ABC. Luego se compara su respuesta con las medidas de temperatura del estator, se ajustan de nuevo los parámetros y se realimenta el modelo. El proceso de optimización se ejecuta un número predeterminado N de veces.




Figura 4. Diagrama de bloques para la identificación de parámetros del modelo térmico.

Luego de ejecutar dicho proceso de optimización (figura 4) para los datos de entrada se obtuvo los resultados que se muestran en de la Tabla 1 .

Tabla 1.Parámetros térmicos del motor de 2 Hp, 230V, 60Hz.

Símbolo	Valor
C_s	5587.15 J/°C
C_r	5096.83 J/°C
G_s	4.19 W/°C
G_r	0 W/°C
G_{sr}	12.79 W/°C
Mejor aptitud	0.533

VALIDACIÓN DE RESULTADOS

Alternativamente, podemos estimar las capacitancias térmicas del estator y rotor C_s y C_r a partir de la masa del componente y su el calor específico, usando las ecuaciones aproximadas:

$$C_s = m_{s,ir} \cdot c_{s,ir} + m_{s,cu} \cdot c_{s,cu} \quad (11)$$

$$C_r = m_{r,ir} \cdot c_{s,ir} + m_{r,al} \cdot c_{s,cu} \quad (12)$$

Como se hace en [17], el vector obtenido para las capacitancias $\mathbf{C} = [C_s \ C_r]^T = [4780 \ 3240]^T \text{ J/°C}$. Por otro lado, las conductancias térmicas G_s, G_r, G_{sr} pueden calcularse usando las fórmulas que propone Boglietti en [24], tal y como se elaboró en [17], obteniéndose que el vector de conductancias $\mathbf{G} = [G_s, G_r, G_{sr}]^T = [4.06 \ 0.026 \ 11.26]^T \text{ W/°C}$.

Es de esperar que las capacitancias y conductancias térmicas calculadas de esta forma no sean muy exactas, pues para su cálculo se usaron valores aproximados para las dimensiones del motor, los materiales y para constantes físicas. Incluso algunas constantes constructivas del motor se debieron estimar según la literatura [24]. Estos parámetros se han calculado de esta forma con el objetivo de tener una idea del orden de magnitud de sus valores. En [17] se presenta la estimación de los parámetros térmicos mediante un algoritmo genético (**GA**), obteniéndose los valores que se muestran en la Tabla 2.

Tabla 2. Parámetros térmicos del motor de 2 Hp, 230V, 60Hz con otros métodos.

Parámetros	Técnica		
	Experimental	GA	ABC
C_s	4780 J/°C	5561.66 J/°C	5587.15 J/°C
C_r	3240 J/°C	5129.74 J/°C	5096.83 J/°C
G_s	4.06 W/°C	4.19 W/°C	4.19 W/°C
G_r	0.026 W/°C	0 W/°C	0 W/°C
G_{sr}	11.26 W/°C	12.36 W/°C	12.79 W/°C

Como se observa en la Tabla 2 los distintos métodos usados generan valores muy similares, siendo los valores obtenidos mediante las técnicas metaheurísticas **AG** y **ABC** prácticamente los mismos, como se muestra en la Tabla 3.

Tabla 3. Valor absoluto del Error en los Parámetros térmicos

Parámetros	Error relativo: AG y ABC
C_s	0.45%
C_r	0.64%
G_s	0%
G_r	0%
G_{sr}	3.3%

CONCLUSIONES

Para obtener las conductancias térmicas G y las capacitancias térmicas C , en la literatura se proponen una serie de técnicas por ejemplo: [8], [9], [20], [21], [27]. Este trabajo comprueba la factibilidad de usar los algoritmos bioinspirados como el ABC para estimar los parámetros térmicos del motor eléctrico sin necesidad de conocer sus características físicas, tales como: materiales, dimensiones, masas, calores específicos, etc., que son muchas veces de difícil obtención.

La exactitud de los parámetros obtenidos se aprecia en el casi perfecto ajuste de la curva experimental y la curva estimada para el mismo punto, en este caso la Figura 5 muestra la casi superposición de la curva experimental de temperatura del estator y la estimación de temperatura usando el modelo (6) y los resultados de la Tabla 1. Además, dadas las características malladas del modelo utilizado, es posible estimar el comportamiento dinámico en otros puntos de interés de muy difícil acceso, por ejemplo el comportamiento dinámico de la temperatura del núcleo rotórico del motor.




Figura 5. Ajuste de temperaturas entre la medida y la estimada.

AGRADECIMIENTO

Se agradece a la Vicerrectora de Investigación por el financiamiento brindado al proyecto SEMAT, código VIE 5402-1341-1301, así como a los asistentes vinculados en este proyecto.

REFERENCIAS

- [1] H. Oraee, "A quantitative approach to estimate the life expectancy of motor insulation systems," *IEEE Trans. Dielectr. Electr. Insul.*, vol. 7, no. 6, pp. 790–796, 2000.
- [2] P. Pillay and M. Manyase, "Loss of life in induction machines operating with unbalanced supplies," *IEEE Trans. Energy Convers.*, vol. 21, no. 4, pp. 813–822, 2006.
- [3] Z. Gao, "SENSORLESS STATOR WINDING TEMPERATURE ESTIMATION FOR INDUCTION MACHINES," Georgia Institute of Technology, 2006.
- [4] S. E. Zocholl, "Comparing motor thermal models," in *In 31st Annual Western Protective Relay Conference*, 2004, pp. 1–10.
- [5] G. Kylander, "Thermal modelling of small cage induction motors," Chalmers University of Technology, 1995.
- [6] a. L. Shenkman and M. Chertkov, "Experimental method for synthesis of generalized thermal circuit of polyphase induction motors," *IEEE Trans. Energy Convers.*, vol. 15, no. 3, pp. 264–268, 2000.

- [7] B. Dutta and S. K. Chowdhury, "Steady state thermal model of TEFC induction machine," in *IEEE International Conference on Emerging Technologies and Factory Automation, ETFAPower Electronics, Drives and Energy Systems (PEDES), 2012*, 2012, pp. 1–6.
- [8] M. J. Duran and J. Fernandez, "Lumped-Parameter Thermal Model for Induction Machines," *IEEE Transactions on Energy Conversion*, vol. 19, pp. 791–792, 2004.
- [9] J. F. Moreno, F. P. Hidalgo, and M. D. Martínez, "Realisation of tests to determine the parameters of the thermal model of an induction machine," *IEE Proceedings - Electric Power Applications*, vol. 148, p. 393, 2001.
- [10] "IEEE Standard Test Procedure for Polyphase Induction Motors and Generators," *IEEE Std 112-2004 (Revision IEEE Std 112-1996)*, pp. 0_1–79, 2004.
- [11] I. Boldea and S. A. Nasar, *The Induction Machine Handbook*. CRC Press, 2002.
- [12] S. Bin Lee and T. G. Habetler, "An online stator winding resistance estimation technique for temperature monitoring of line-connected induction machines," *IEEE Trans. Ind. Appl.*, vol. 39, no. 3, pp. 685–694, 2003.
- [13] Z. Gao, T. G. Habetler, R. G. Harley, and R. S. Colby, "An Adaptive Kalman Filtering Approach to Induction Machine Stator Winding Temperature Estimation Based on a Hybrid Thermal Model," *IEEE Ind. Appl. Conf.*, pp. 2–9, 2005.
- [14] K. Cho and J. Seok, "Induction Motor Temperature Estimation Based on High-Frequency Model of Rotor Bar," in *Industry Applications Society Annual Meeting, 2008. IAS '08. IEEE*, 2008, no. 1, pp. 1–7.
- [15] L. D. Murillo-Soto and G. Figueroa-Mata, "Obtención de parámetros de un modelo térmico para un motor trifásico usando algoritmos genéticos," in *13th LACCEI Annual International Conference*, 2015, pp. 1–2.
- [16] L. D. Murillo-Soto, "Aplicación informática para el monitoreo de variables eléctricas, mecánicas y térmicas en motores trifásicos de inducción," in *Latin American and Caribbean Conference for Engineering and Technology (LACCEI'2014)*, 2014.
- [17] L. D. Murillo-Soto and G. Figueroa-Mata, "Identificación de parámetros de un modelo térmico para un motor trifásico de inducción usando algoritmos genéticos," *Tecnol. en Marcha*, vol. 29, no. Y (Por aparecer), 2016.
- [18] D. Karaboga, "An idea based on Honey Bee Swarm for Numerical Optimization," *Tech. Rep. TR06*, Erciyes Univ., no. TR06, p. 10, 2005.
- [19] D. Karaboga and B. Akay, "Artificial Bee Colony (ABC) Algorithm on Training Artificial Neural Networks," in *2007 IEEE 15th Signal Processing and Communications Applications*, 2007.
- [20] D. Karaboga and C. Ozturk, "Fuzzy clustering with artificial bee colony algorithm," *Sci. Res. Essays*, vol. 5, no. 14, pp. 1899–1902, 2010.
- [21] K. S. Kaswan, S. Choudhary, and K. Sharma, "Applications of Artificial Bee Colony Optimization technique: Survey," in *Applications of Artificial Bee Colony Optimization technique: Survey*, 2015, pp. 1660–1664.
- [22] T. Liao, D. Aydın, and T. Stützle, "Artificial bee colonies for continuous optimization: Experimental analysis and improvements," *Swarm Intell.*, vol. 7, no. 4, pp. 327–356, 2013.
- [23] D. Karaboga, B. Gorkemli, C. Ozturk, and N. Karaboga, "A comprehensive survey: artificial bee colony (ABC) algorithm and applications," *Artif. Intell. Rev.*, vol. 41, no. 1, pp. 21–57, 2014.
- [24] A. Boglietti, A. Cavagnino, M. Lazzari, and M. Pastorelli, "A Simplified Thermal Model for Variable-Speed Self-Cooled Industrial Induction Motor," *IEEE Trans. Ind. Appl.*, vol. 39, no. 4, pp. 945–952, 2003.
- [25] S. E. Zocholl, E. O. Schweitzer, and A. Aliaga-Zegarra, "Thermal Protection of Induction Motors Enhanced by Interactive Electrical and Thermal Models," *IEEE Trans. Power Appar. Syst.*, vol. PAS-103, no. 7, pp. 1749–1755, 1984.
- [26] O. I. Okoro, B. Weidemann, and O. Ojo, "An efficient thermal model for induction machines," *Conf. Rec. 2004 IEEE Ind. Appl. Conf. 2004. 39th IAS Annu. Meet.*, vol. 4, 2004.
- [27] A. Boglietti, A. Cavagnino, and D. Staton, "Determination of Critical Parameters in Electrical Machine Thermal Models," *IEEE Trans. Ind. Appl.*, vol. 44, no. 4, pp. 1150–1159, 2008.

Identificación de parámetros de un modelo térmico para un motor trifásico de inducción usando algoritmos genéticos

Parameters identification of a thermal model for a three-phase induction motor using genetic algorithm

Luis Diego Murillo-Soto¹, Geovanni Figueroa-Mata²,
Osvaldo Guerrero-Castro³

Fecha de recepción: 19 de junio del 2015
Fecha de aprobación: 26 de setiembre del 2015

Murillo-Soto, L.; Figueroa-Mata, G; Guerrero-Castro, O. Identificación de parámetros de un modelo térmico para un motor trifásico de inducción usando algoritmos genéticos. *Tecnología en Marcha*. Edición especial. Matemática Aplicada, Mayo 2016. Pág 25-41.

¹ Profesor Asociado, Máster en Computación, Instituto Tecnológico de Costa Rica, : lmurillo@tec.ac.cr

² Profesor Catedrático, Máster en Computación,, Instituto Tecnológico de Costa Rica, gfigueroa@tec.ac.cr

³ Profesor Catedrático, Máster en Administración de la Ingeniería Electromecánica,, Instituto Tecnológico de Costa Rica, oguerrero@tec.ac.cr

Palabras claves

Algoritmo genético; modelo térmico del motor de inducción; identificación.

Resumen

Una forma alternativa de identificar los parámetros de un modelo térmico de un motor de inducción es por medio de algoritmos genéticos. Este trabajo en su inicio, describe brevemente los conceptos relacionados con los modelos térmicos de motores, así como los principales conceptos de los algoritmos genéticos. Posteriormente plantea un modelo térmico simplificado para un motor trifásico Baldor modelo M3558, de 2 hp, 230V, 60 Hz, dicho modelo posee dos nodos para los cuales se plantean sus ecuaciones diferenciales y sus soluciones analíticas. Para determinar los parámetros de este modelo térmico se alimenta un algoritmo genético con el cálculo de las pérdidas del motor eléctrico así como las temperaturas del motor capturadas por un banco de pruebas construido para tal fin. El algoritmo genético va modificando cada parámetro de la solución analítica hasta que se cumplan los criterios de ajuste. En la parte final del trabajo se confrontan las capacitancias y conductancias térmicas obtenidas contra cálculos teóricos de las constantes físicas del motor. Se muestra que los parámetros obtenidos con el algoritmo genético presentan un mejor ajuste respecto a los datos y no requieren del conocimiento de las magnitudes y constantes físicas relacionadas con el motor.

Keywords

Genetic algorithms; induction motor thermal model; parameter identification.

Abstract

Genetics algorithms are an alternative way to identify the parameters of an induction motor thermal model. Initially, this work briefly describes the concepts related to electric motors thermal models and the key concepts of genetic algorithms. Then it presents a simplified model for an M3558 Baldor motor, 2 HP, 230V, 60 Hz, the thermal model have two nodes, a set of differential equations and its analytical solutions is derived for each one. To determine the parameters of the thermal model, a genetic algorithm is fed with the calculation of motor losses and temperatures captured by a tests bench. The genetic algorithm changes each parameter of the analytical solution until adjustment criteria are met. At the end of this work, the thermal capacitances and inductances obtained are compared with theoretical calculations of the physical constants of the motor. We demonstrate that the parameters obtained with genetic algorithms fit better to the data and require little knowledge of the magnitude and physical constants related to the motor.

Introducción

Debido a que los motores eléctricos de inducción representan la principal fuerza motriz para accionar los sistemas electromecánicos, estimar de forma correcta la temperatura interna de la máquina es una necesidad por su efecto sobre la vida útil de la máquina. Los materiales y barnices aislantes del motor se degradan de forma exponencial, por cada 10°C por encima de la temperatura máxima de la clase de aislamiento la vida útil se reduce a la mitad (Oraee, 2000; Pillay & Manyage, 2006).

$$L_x = L_{100} \cdot 2^{(T_c - T_x)/k} \quad (1)$$

Donde L_x representa la estimación de la vida útil en la nueva condición de operación, L_{100} es la vida útil proyectada de fábrica usualmente 20.000 horas, T_x es la nueva temperatura de operación, T_c es la temperatura de la clase del aislamiento y k es una constante definida para cada clase de aislamiento donde 14, 11, 9.3, 8, y 10 corresponden a los aislantes clase A, B, F, H y H'.

La estimación de la temperatura interna del motor se puede dividir en cinco grandes estrategias tal y como se muestra en la figura 1.

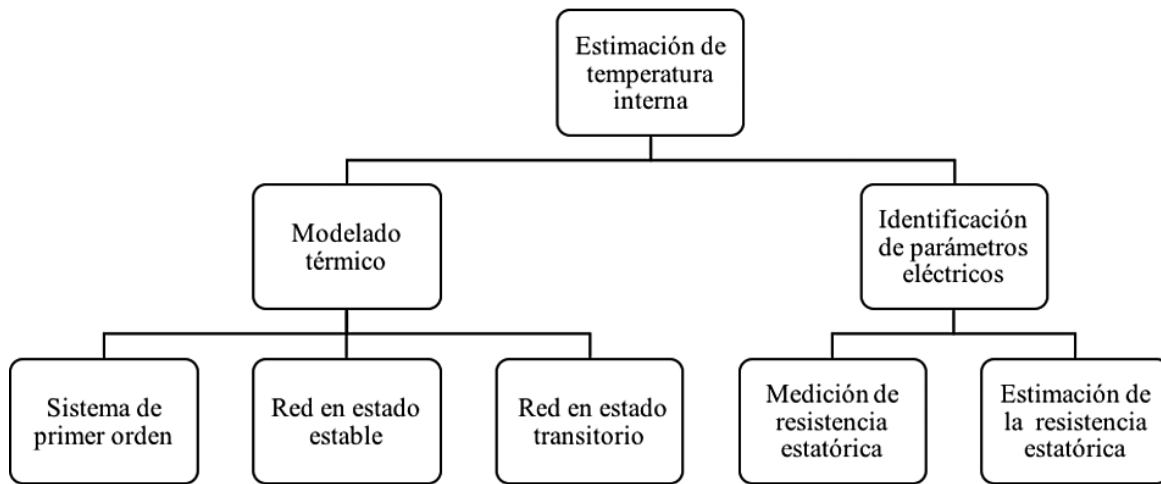


Figura 1. Clasificación de los métodos para estimar temperaturas.

De acuerdo con (Gao, 2006), los modelos de primer orden son rápidos y eficientes, presentan una buena estimación de la temperatura y necesitan solamente la corriente estática, pero su estimación es un promedio general que no permite determinar los puntos calientes de la máquina. En (Zocholl, 2004) se realiza una comparación entre distintos tipos de modelos de primer orden, los cuales poseen una estructura similar a la ecuación (2).

$$\theta = I^2 R R_{th} \left(1 - e^{\frac{-t}{R_{th} C_{th}}} \right) + \theta_A \quad (2)$$

Donde θ y θ_A son las temperaturas interna y la ambiental respectivamente, el término PR representa la totalidad de pérdidas del motor, R_{th} representa una resistencia térmica equivalente y C_{th} representa la capacitancia térmica del motor.

Por su parte, los modelos térmicos mallados para estados estables permiten predecir la temperatura en zonas específicas de la máquina, con el inconveniente de que la estimación de temperaturas en el transitorio térmico presenta errores de hasta el 100%. Estos modelos en estado estable tales como los que se plantean en (Kylander, 1995; Shenkman & Chertkov, 2000; Dutta & Chowdhury, 2012), obtienen las temperaturas resolviendo sistemas de ecuaciones lineales (3), donde P es el vector de pérdidas de la máquina, G es la matriz de conductancias térmicas del motor y θ es el vector de temperaturas a calcular.

$$P = G \theta \quad (3)$$

Los modelos térmicos mallados para estados transitorios son aquellos que pueden predecir la temperatura en un punto específico de la máquina, tanto en régimen transitorio como en estado estable. Estos modelos incorporan un tercer vector a la ecuación (3), el cual se forma al

multiplicar una matriz C que contiene en su diagonal las capacitancias térmicas de la máquina, por un vector que contiene las derivadas de las temperaturas respecto al tiempo $d\theta/dt$, de tal forma que la expresión general queda:

$$C \frac{\partial \theta}{\partial t} = P - G\theta \quad (4)$$

Los modelos complejos que muestran el estado transitorio tal como y como se plantean (Oraee, 2000; Duran & Fernandez, 2004; Moreno, Hidalgo, & Martínez, 2001) ofrecen una predicción de la temperatura en el respectivo nodo, pero para poderla estimar se requiere conocer los materiales, geometrías, dimensiones y masas para calcular cada conductancia térmica entre los nodos G y la matriz de capacitancia C . Además, es necesario conocer en forma detallada cada una de las pérdidas reales P de la máquina, para eso se debe realizar pruebas de laboratorio. Cabe señalar que estos inconvenientes también se presentan en los modelos en estado estable, ecuación (3).

La estimación de la temperatura con base en parámetros eléctricos, se divide en dos esquemas fundamentales. El primero surge del estándar IEEE 112 ("IEEE Standard Test Procedure for Polyphase Induction Motors and Generators," 2004), en donde se indica que la variación de la temperatura interna provoca variaciones de las resistencias estáticas y rotóricas del motor en la siguientes proporciones.

$$R_2 = R_1 \frac{\theta_2 + k}{\theta_1 + k} \quad (5)$$

$$\theta_2 = \frac{R_2}{R_1} (\theta_1 + k) - k \quad (6)$$

Donde R_1 representa la resistencia a la temperatura θ_1 , usualmente medido a temperatura ambiente con motor apagado, R_2 la resistencia a la temperatura θ_2 y k es el coeficiente del material conductor, que para el cobre es 234.5 y para el aluminio es de 225. La ecuación (6) muestra el resultado de despejar la temperatura interna. Para obtener el valor de las resistencias se utilizan dos métodos, el primero calcula la resistencia aplicando la ley de Ohm a la medición del voltaje y corriente continua (CD). El segundo es la medición directa con puente wheatstone doble, mediante un miliohmímetro. Consecuentemente y dado que el punto más caliente de una máquina es el devanado estático (Boldea & Nasar, 2002), la medición de la resistencia estática es el método más sencillo para la estimación de temperaturas.

La desventaja del esquema de medición de la resistencia estática es que es invasivo, ya que requiere de equipamiento adicional y desconectar eléctricamente la máquina. Por tal motivo se han venido desarrollando métodos alternativos de obtención de la resistencia estática a partir de mediciones eléctricas de voltajes y corrientes, (Gao, 2006; Gao, Habetler, Harley, & Colby, 2005) o frecuencias (Cho & Seok, 2008). La idea de estos trabajos es desarrollar equipos en tiempo real que operen en línea con el motor y que realicen los respectivos cálculos de la estimación de temperatura interna. El principal inconveniente de estos métodos es que estiman la temperatura interna del devanado, pero no estima el comportamiento de temperaturas en otras zonas de interés en el motor, tal como la temperatura del núcleo, roles, carcasa, etc. Por otro lado, si se aplican técnicas metaheurísticas es posible estimar los parámetros de los modelos térmicos (3) y (4) que es la propuesta del presente trabajo.

Algoritmo genético

Los algoritmos genéticos (GA) fueron desarrollados por John Holland en la década de los años 70. Se fundamentan en los principios biológicos de la evolución de las especies: selección natural y supervivencia del más fuerte.

Son algoritmos poblacionales, ya que trabajan con un conjunto de soluciones factibles llamado población. De este modo, en lugar de pasar de una única solución a la siguiente, se pasa

de una población a otra mediante la combinación y mutación de soluciones factibles. La combinación de soluciones factibles se lleva a cabo mediante cruzamiento, con la esperanza de producir descendientes mejor adaptados que sus ancestros. De esta manera, la especie evoluciona adaptándose mejor al entorno. Eventualmente, se producen mutaciones con la idea de producir descendientes con características distintas a las de sus progenitores, estas son las causantes de la aparición de individuos superiores. Sin mutaciones la especie no podría evolucionar hacia organismos más complejos y mejor adaptados a su medio. Por esta razón, el proceso de mutación se considera primordial en el proceso de evolución (Talbi, 2009).

La selección de individuos que formarán la nueva generación, buscan imitar la selección natural, en el sentido de que los individuos más adaptados tienen mayor probabilidad de ser seleccionados para formar la nueva generación mediante cruzamiento y mutación.

Existen muchas formas de realizar el proceso de selección. Entre las más usadas están los métodos de selección estocástica como la selección por ruleta simple y la selección por torneo determinístico o probabilístico.

Los algoritmos genéticos tradicionalmente se utilizan resolver problemas de búsqueda y/o optimización, en los cuales se tiene que determinar la mejor solución de un conjunto de soluciones factibles de gran tamaño.

A cada uno de las soluciones factibles de una generación se le asocia un valor llamado aptitud. Este valor cuantifica la calidad de la solución y permite comparar soluciones de la misma generación y/o con soluciones de generaciones anteriores.

Entrada: Parámetros del algoritmo
Salida: Individuo mejor adaptado (mejor solución)

- 1: $t \leftarrow 0$
- 2: Generar la población inicial P_0 con m individuos
- 3: Mientras no se haya satisfecho el criterio de parada
- 4: Calcular la aptitud de cada individuo en P_t
- 5: $P_t \leftarrow \text{Cruzar}(P_t)$
- 6: $P_t \leftarrow \text{Mutar}(P_t)$
- 7: $t \leftarrow t+1$
- 8: Construir la nueva población P_t
- 9: fin
- 10: Retornar la mejor solución obtenida.

Figura 2. Algoritmo genético básico.

El algoritmo genético comienza con una población inicial de soluciones factibles, que se construye usualmente de forma aleatoria. Se evalúa la aptitud de cada individuo de la población y se construye nueva población mediante cruzamiento, mutación y selección. Este proceso se repite hasta que se satisfaga algún criterio de parada, como se muestra en la figura 2.

Con respecto a la convergencia de un algoritmo genético, Rudolph (Rudolph, 1994), demuestra que las variantes de un algoritmo genético básico que mantengan en la población, antes o después de la selección, la mejor solución hallada a lo largo del tiempo, siempre converge al óptimo global. Esto no se puede garantizar cuando se utiliza la selección elitista pues el mejor individuo no sólo se mantiene sino que también se utiliza para generar nuevos individuos y el algoritmo tiene una matriz de transición diferente y, por tanto, diferentes dinámicas de búsqueda que pueden ser mejores en algunos casos y peores en otros.

Modelo Térmico Propuesto

El modelo térmico que se utiliza para el motor de estudio fue propuesto por (Duran y Fernandez, 2004; Moreno, Hidalgo y Martínez, 2001). Este modelo se construye a partir de la ecuación general (4). El modelo de la figura 3, posee sólo dos nodos llamados θ_s y θ_r que representan la temperatura promedio del estator y del rotor respectivamente. Por otra parte, la temperatura θ_o se refiere a la temperatura ambiental. El modelo representa las pérdidas de potencia del motor como fuentes de calor que elevan las temperaturas internas. La fuente del estator es llamada P_s y la del rotor P_r . Los capacitores térmicos C_s y C_r representan la capacidad del estator y el rotor de almacenar calor, son el producto de la masa del componente por el calor específico del material.




Figura 3. Modelo térmico de un motor eléctrico de inducción. Adaptado de Duran y Fernandez, (2004).

Estimación de las pérdidas

El incremento de temperatura dentro de un motor de inducción es causado por la energía que no se logra transformar por unidad de tiempo y se desperdicia como calor, es decir las pérdidas son resultado de un deficiente proceso de conversión de energía eléctrica a mecánica. Por lo tanto, la pérdida total P_T es la diferencia de potencia de la entra P_{Ent} menos la potencia de salida P_{Sal} de la máquina. Estas pérdidas usualmente se agrupan en tres clases: las llamadas pérdidas fijas P_f las pérdidas variables P_v y pérdidas misceláneas P_{st} .

$$P_T = P_{Ent} - P_{Sal} = P_f + P_v + P_{st} \quad (7)$$

Las pérdidas fijas P_f son aquellas que se asocian a las pérdidas en el núcleo del motor P_N más las pérdidas mecánicas P_M , ecuación (8). La pérdida P_N se compone de la pérdida por histéresis P_H más la pérdida que producen las corrientes parásitas P_F . Las pérdidas mecánicas P_M se componen a su vez de las pérdidas por fricción en rodamientos P_R y por las pérdidas por vendaval P_V . De acuerdo con Fraile-Mora (2008) las potencia por pérdida en núcleo y mecánica se modelan como :

$$P_f = P_N + P_M \quad (8)$$

$$P_N = P_H + P_F = (k_H f B_m^\alpha + k_F f^2 B_m^2 a^2 \sigma) v \quad (9)$$

$$P_M = P_R + P_V = A\omega + B\omega^3 \quad (10)$$

Para la ecuación (9) las constantes k_H y k_F representan los efectos de histéresis y de Foucault respectivamente, f es la frecuencia, B_m es el campo magnético máximo, los parámetros α, a, σ, v representan las constantes de diseño: el espesor de placas, la conductividad y volumen del hierro respectivamente. Para la ecuación (10) A, B son constantes y ω representa la velocidad del eje.

Dado que en la ecuación (9) todos los parámetros son constantes a excepción de la frecuencia de funcionamiento y el campo magnético, pero estos son prácticamente constantes, entonces se dice que la potencia P_N es constante en la curva de bajo deslizamiento. Eventualmente el contenido armónico de la señal de voltaje incrementa estas pérdidas, ya que existirán frecuencias múltiplos de f que generan campos magnéticos residuales que se suman a las pérdidas provocada en la frecuencia fundamental. De igual forma sucede con las pérdidas mecánicas (10), la velocidad de régimen es prácticamente constante, y varía muy poco respecto a la velocidad en vacío. Las pérdidas fijas se obtienen aplicando la prueba en vacío que aparece en la norma IEEE 112 ("IEEE Standard Test Procedure for Polyphase Induction Motors and Generators" 2004), y la ecuación siguiente para cada voltaje:

$$P_f = P_{Ent0} - P_{Cu0} \quad (11)$$

donde P_{Ent0} es el consumo de potencia del motor cuando este no posee carga en el eje y P_{Cu0} se refiere a las pérdidas por efecto Joule de la resistencia por fase R_e del devanado estatórico, de tal forma que para un sistema que presenta corrientes con desbalance se puede calcular como:

$$P_{Cu0} = R_e (I_{A0}^2 + I_{B0}^2 + I_{C0}^2) \quad (12)$$

donde I_{A0}, I_{B0}, I_{C0} se refieren a las corrientes en vacío de cada una de las fases.

Las pérdidas variables P_v son todas aquellas que dependen del porcentaje de carga del motor y por tanto de la corriente que pasa por los conductores. Estas pérdidas son producto del efecto Joule en la resistencia del devanado estatórico P_{CuE} , así como en las barras del rotor P_{CuR} .

$$P_{CuE} = R_e (I_A^2 + I_B^2 + I_C^2) \quad (13)$$

donde R_e se refiere a la resistencia a temperatura ambiente y I_A, I_B, I_C a las corrientes por fase.

La potencia de pérdida del rotor P_{CuR} se calcula como:

$$P_{CuR} = P_{Ent} - P_{Sal} - P_{CuE} - P_f - P_{st} \quad (14)$$

donde P_{st} se refiere a la potencia miscelánea que según la norma "IEEE Standard Test Procedure for Polyphase Induction Motors and Generators" (2004) se estima como el 1.8% de la potencia

de salida para máquinas menores a 90kW. Otra forma de estimar esta potencia es conociendo el deslizamiento en el punto de operación de la máquina y la potencia de pérdida del núcleo P_N . Para máquinas de 4 polos las pérdidas mecánicas P_M no superan el 1.5% de la potencia de salida según Kim, Choi, Chun, Koo, y Han, (2014), por lo que la potencia de pérdida del rotor se puede calcular como,

$$P_{CuR} = (P_{Ent} - P_{CuE} - (P_f - P_M))s \quad (15)$$

De acuerdo con el modelo planteado en la sección anterior, la potencia que se pierde en el estator P_s y en el rotor P_r se calculan como:

$$P_s = (P_{CuE} + (P_f - P_M)) \quad (16)$$

$$P_r = P_{CuR} \quad (17)$$

Deducción del modelo

A partir de la ecuación (4) y del modelo térmico de la figura 3, se obtiene el sistema de ecuaciones diferenciales de primer orden, con sus condiciones iniciales:

$$\begin{bmatrix} C_s & 0 \\ 0 & C_r \end{bmatrix} \begin{bmatrix} \frac{d\theta_s}{dt} \\ \frac{d\theta_r}{dt} \end{bmatrix} = \begin{bmatrix} P_s \\ P_r \end{bmatrix} - \begin{bmatrix} (G_s + G_{sr}) & -G_{sr} \\ -G_{sr} & (G_r + G_{sr}) \end{bmatrix} \begin{bmatrix} \theta_s \\ \theta_r \end{bmatrix} \quad (18)$$

$$\theta(0) = \begin{bmatrix} 0 \\ 0 \end{bmatrix}$$

Donde dichas condiciones significan que el motor se encuentra a temperatura ambiente, es decir $\theta_s(0) = 0$ y $\theta_r(0) = 0$.

Se solucionó de forma analítica la ecuación (18) y se obtuvieron las ecuaciones (19) que modelan la temperatura del estator θ_s y del rotor θ_r en función de los parámetros térmicos.

$$\begin{aligned} \theta_s &= C_1 e^{r_1 t} + C_2 e^{r_2 t} + \frac{E}{B} \\ \theta_r &= C_3 e^{r_1 t} + C_4 e^{r_2 t} + \frac{F}{B} \end{aligned} \quad (19)$$

donde las constantes de (19) en función de los parámetros son:

$$C_1 = \frac{E(r_2 C_s + G_s + G_{sr}) - F G_{sr}}{B C_s (r_1 - r_2)}$$

$$C_2 = \frac{E(r_1 C_s + G_s + G_{sr}) - F G_{rs}}{B C_s (r_2 - r_1)}$$

$$C_3 = \frac{C_1(r_1 C_s + G_s + G_{sr})}{G_{sr}}$$

$$C_4 = \frac{C_2(r_2 C_s + G_s + G_{sr})}{G_{sr}}$$

$$B = \frac{G_s G_r + G_s G_{sr} + G_r G_{sr}}{C_s C_r}$$

$$E = \frac{G_r P_s + G_{sr} P_s + G_{sr} P_r}{C_s C_r}$$

$$F = \frac{G_s P_r + G_{sr} P_r + G_{sr} P_s}{C_s C_r}$$

Donde r_1, r_2 son las soluciones de la ecuación característica asociada.

Banco de pruebas y adquisición de datos

El banco de pruebas para motores trifásicos se compone de un generador de corriente directa de 5 kW y un banco de resistencias de 7 kW. El banco posee tres autotransformadores monofásicos conectados en estrella para provocar bajos y altos voltajes de alimentación así como desbalances, finalmente poleas y fajas para acoplar mecánicamente el motor al generador tal como se aprecia en la figura 4a.

Se ha desarrollado un software (Murillo-Soto, 2014) que gestiona el banco de pruebas y somete los motores a experimentos controlados en los que se definen los parámetros de la prueba. Se controlan los estímulos del motor (carga, tiempos de encendido o apagado), se monitorea su reacción y finalmente se registran todas las variables de interés.

La aplicación informática se desarrolló desde el paradigma de programación gráfica usando *LabView* v12.0. La aplicación posee una arquitectura cliente-servidor punto a punto y se compone de dos programas uno que se ejecuta en una computadora personal y el otro que se ejecuta en un controlador de tiempo real C-RIO 9073 de National Instruments, tal como se muestra en la figura 4b. Los siete módulos que tiene instalado el C-RIO instalados son: un NI-9227 para corrientes trifásicas, un NI-9225 para voltajes trifásicos, un NI-9422 para entradas digitales, un NI-9478 para salidas digitales, un NI-9207 para entradas analógicas de voltaje, un NI-9263 para salidas analógicas, un módulo NI-9219 universal para RTD y un NI-9213 para termopilas j y k.

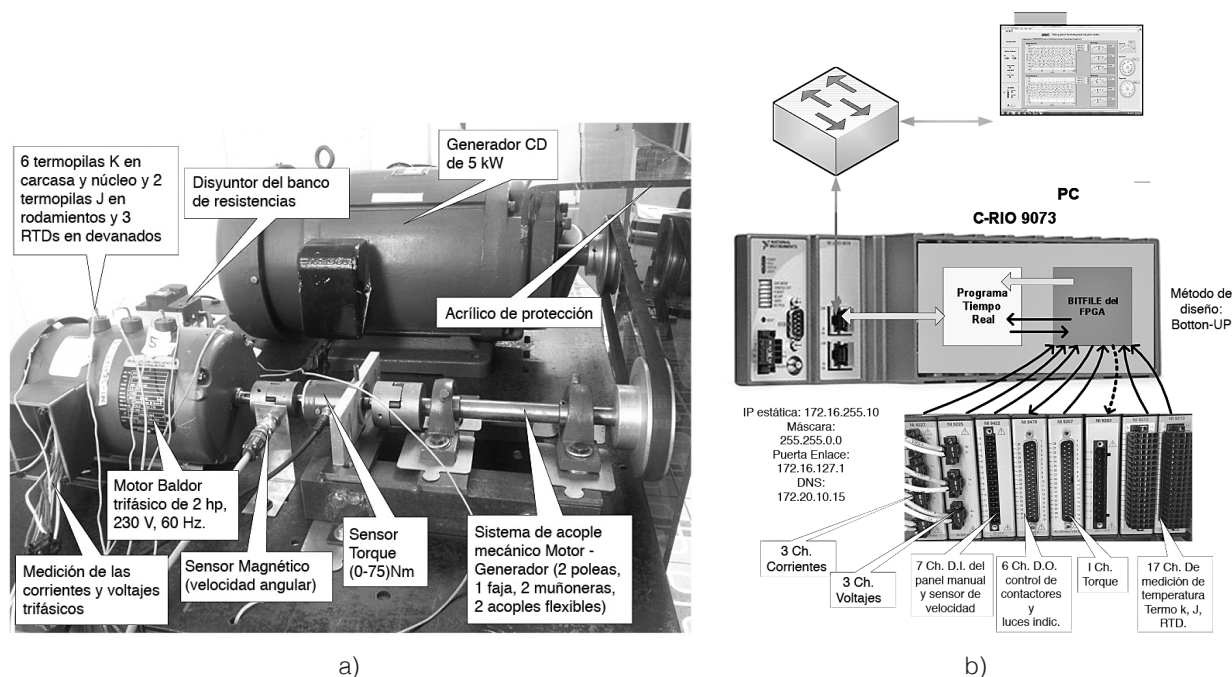


Figura 4. a) Fotografía del banco de pruebas implementado b) Flujo de datos entre la interfaz gráfica y la tarjeta de adquisición de datos, las flechas indican la dirección del flujo de información. Tomado de Murillo-Soto, (2014).

El programa que corre en la PC se conecta mediante una red Ethernet usando el protocolo TCP/IP al controlador C-RIO 9073. Este software controla el encendido y apagado del motor seleccionado, muestra las señales trifásicas de corrientes, voltajes y brinda los valores de torque y la velocidad angular del eje. Además muestra en una gráfica las 11 mediciones de

temperaturas del motor segregadas de la siguiente forma: las temperaturas de cada devanado del motor trifásico, la medición de temperatura de cada rodamiento, dos temperaturas en el núcleo, tres temperaturas en la carcasa y la temperatura ambiental.

Además el software de la PC calcula los valores RMS de corriente y voltaje trifásicos, así como el contenido espectral de las señales. Adicionalmente se calculan los ángulos de fase, las potencias de entrada y salida del motor, calcula y grafica la evolución de la eficiencia de la máquina, calcula el desbalance de la red, el contenido armónico de voltaje y corrientes, así como las potencias reactivas, aparentes y el factor de potencia. Este software permite exportar todas las 28 variables capturadas en dos tipos de archivos de extensión lvm.

El software que se ejecuta en el C-RIO configura cada uno de los ocho módulos del sistema, su frecuencia de muestro, la sincronización entre módulos de adquisición, el tratamiento de los datos (filtrado), la conversión de datos crudo a variables con significado físico (escalamiento), etc. El controlador manipula salidas digitales para señalización externa, control de contactores y control de un relé de estado sólido mediante modulación de ancho de pulso para el control de la carga eléctrica del generador, que su vez se traduce en carga mecánica en el motor. El software del C-RIO tiene programada la protección de sobrecarga, la protección a un determinado valor de desbalance del voltaje y la protección a valores de contenido armónico superiores a un umbral definido por el usuario.

Cálculo del vector de pérdidas

El motor en estudio es de la marca Baldor modelo M3558 de 2hp, 230 V, 60 Hz. Lo primero que se realizó son las mediciones de las resistencias estáticas con un miliohmímetro, el cual arroja los valores por fase de $R_e = 1.03\Omega$. Luego se realizó la prueba del motor en vacío la cual permite calcular las pérdidas fijas P_f ecuación (8), esta prueba consiste en desacoplar la carga mecánica y energizar la máquina con el fin de registrar la potencia de entrada P_{Ent0} y las corrientes de vacío por fase $\{I_{A0}, I_{B0}, I_{C0}\}$. Con dichas corriente se calcula la pérdida de potencia por efecto Joule en vacío, ecuación (12). Luego se reduce el voltaje y para cada cambio se registran la potencia de entrada en vacío y los nuevos valores de corrientes consumida. De esta forma aplicando las ecuaciones (11) y (12) se obtiene la potencia fija para cada voltaje, y se grafica como se muestra en la figura 5. Por lo tanto, las pérdidas de potencias obtenidas para voltaje nominal son: $P_f = 204,3 \text{ W}$, $P_N = 200,4 \text{ W}$ y $P_M = 3,9 \text{ W}$ respectivamente.




Figura 5. Pérdidas fijas del motor de 2 hp, 230 V, 60 Hz del laboratorio.

Como tercer paso y dado que el sistema de adquisición de datos calcula las potencias de entrada y salida en cada segundo para una carga dada, se utiliza el promedio de los valores registrados. Por ejemplo la ecuación (13) se modifica y se convierte en la ecuación (20), esto con el fin de utilizar los N registros. El valor calculado fue de $P_{CuE}=109.4 \text{ W}$.

$$P_{CuE} = \frac{R_e}{N} \sum_{i=1}^N (I_{Ai}^2 + I_{Bi}^2 + I_{Ci}^2) \quad (20)$$

Con los valores de pérdidas hasta ahora obtenidos y usando la ecuación (16) se obtiene una potencia de pérdida del estator P_s , de 309.8 W .

La potencia promedio de entrada es de $P_{Ent} = 1855.6 \text{ W}$ y la potencia promedio de salida es de $P_{Sal} = 1480.3 \text{ W}$, por lo que la potencia total de pérdidas ecuación (7), es de 375.3 W . Para el cálculo de la potencia de pérdidas del rotor se utilizó la expresión (15) ya que se conoce que el deslizamiento promedio es de 3.4% , por lo que $P_r = P_{Cur} = 52.7 \text{ W}$. La potencia miscelánea P_{st} para este motor sería de 12.8 W . El vector de pérdidas \mathbf{P} del modelo de la ecuación (18) posee por lo tanto los valores: $\mathbf{P} = [309.8, 52.7]^T \text{ W}$.

Identificación de parámetros

Para estimar las conductancias térmicas \mathbf{G} y las capacitancias térmicas \mathbf{C} la literatura propone una serie de técnicas por ejemplo: Duran y Fernández, (2004); Moreno, Hidalgo y Martínez, (2001), Boglietti, Cavagnino y Staton, (2008). Alternativamente usando un algoritmo genético es posible estimar dichos parámetros sin mayores complicaciones como se describe en esta sección. Para estimar los parámetros $\mathbf{G} = [G_s, G_r, G_{sr}]^T$ y $\mathbf{C} = [C_s, C_r]^T$ se compara la respuesta θ_s del modelo de referencia basado en la ecuación (19), con el incremento de temperatura en el estator $\Delta\theta$. El incremento $\Delta\theta$ se entiende como la diferencia entre las temperaturas medidas en el devanado eléctrico θ y la temperatura ambiente $\Delta\theta = \theta - \theta_0$. Los parámetros del modelo de referencia se van ajustando iterativamente mediante un algoritmo genético, de manera tal que la diferencia entre las respuestas de ambos modelos sea mínima.

La figura 6 muestra un diagrama de bloques donde se ilustra dicho proceso. El modelo de referencia se alimenta con el vector de pérdidas $\mathbf{P} = [P_s, P_r]^T$ y los vectores de parámetros a estimar $\mathbf{C} = [C_s, C_r]^T$ y $\mathbf{G} = [G_s, G_r, G_{sr}]^T$ generados por el algoritmo genético. Luego se compara su respuesta con las medidas de temperatura del estator, se ajustan de nuevo los parámetros y se realimenta el modelo. El proceso de optimización se detiene cuando no hay cambios significativos en los vectores de parámetros \mathbf{C} y \mathbf{G} .

La función de incremento de temperatura en el estator $\Delta\theta = \theta - \theta_0$ se puede estimar con precisión, pues se tiene la temperatura en el devanado y la temperatura ambiente, las cuales han sido medidas cada segundo a lo largo de un período de 2 horas 30 minutos. De esta forma la función objetivo a optimizar está dada por la función de error cuadrático medio $\varepsilon = \frac{1}{N} \sum_{i=0}^N (\Delta\theta(t_i) - \theta_s(t_i))^2$ la cual se obtiene restando los datos experimentalmente medidos $\Delta\theta$ y la respuesta del modelo térmico θ_s .

Para optimizar la función objetivo ε con el algoritmo genético, se parte de una población inicial de $m=100$ individuos que son generados de forma aleatoria en el espacio de búsqueda. Cada individuo de la población es un vector $\mathbf{X}^k = [C_s, C_r, G_s, G_r, G_{sr}]^T$ para $k=1, \dots, m$. El espacio de búsqueda se restringió con las siguientes condiciones $0 \leq x_i^k \leq 100000$ para $i=1, \dots, 5$.

El operador de cruzamiento combina la información de dos individuos llamados padres para formar, en la siguiente generación, un nuevo individuo llamado hijo. Existen diferentes tipos de

cruzamiento, se utilizó el llamado cruzamiento heurístico el cual construye el nuevo individuo de la siguiente forma: si P_1 y P_2 son los padres tales que P_1 es el padre mejor adaptado, entonces el nuevo individuo se construye como $H=P_2+R(P_1-P_2)$, donde R es la razón de cruzamiento, en nuestro caso $R=1.2$.

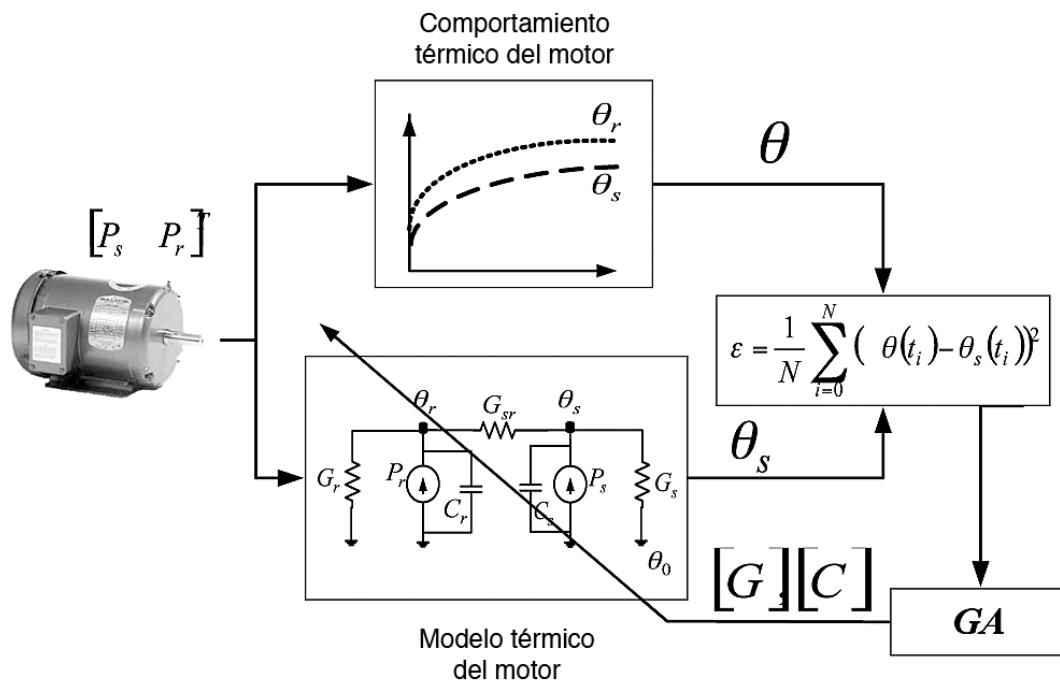


Figura 6. Diagrama de bloques para la identificación de parámetros del modelo térmico.

El operador de mutación realiza aleatoriamente pequeños cambios en los individuos de una población, lo cual provee diversidad genética y amplía el rango de búsqueda. Existen diferentes tipos de mutación, se utilizó la mutación factible adaptativa, la cual genera direcciones de búsqueda aleatorias que son adaptadas de acuerdo al éxito o fracaso de las últimas generaciones. A lo largo de cada dirección se escoge una longitud de avance de modo que se cumplan las restricciones lineales y cotas del problema.

La función de selección elige, tomando en cuenta los valores de aptitud de cada individuo, los padres que se reproducirán para formar la siguiente generación. En nuestro caso la función de selección que se utilizó es el muestreo universal estocástico. Para esta función los individuos son mapeados a un segmento continuo de línea de tal manera que la porción del segmento que se les asigna es proporcional a su aptitud. Se colocan sobre la línea marcas igualmente espaciadas, tantas como padres se quiera seleccionar. El algoritmo se mueve a lo largo de la línea con un paso de avance de igual tamaño. El primer paso de avance es un número aleatorio uniforme menor que las distancias entre las marcas. Los individuos seleccionados son aquellos que están bajo las marcas.

El algoritmo genético se detiene si el cambio acumulado en el valor de la función objetivo a lo largo de las generaciones es menor que la tolerancia de funciones $TolFun=10^{-15}$ o si se alcanza el número máximo de 80000 generaciones que se utilizó. Luego de ejecutar el algoritmo genético para los datos de entrada se obtuvieron los resultados de el cuadro 1.

Cuadro 1. Parámetros térmicos del motor de 2 Hp, 230V, 60Hz.

Símbolo	Valor
C_s	5243.41 J/°C
C_r	5389.43 J/°C
G_s	4.15 W/°C
G_r	3×10^{-8} W/°C
G_{sr}	12.16 W/°C
Mejor aptitud	0.5317
Aptitud promedio	0.5350

Validación

El motor de estudio posee una masa de 16 kg de los cuales 10 kg pertenecen al estator y carcasa y el resto al rotor y al eje. Una primera aproximación para ver el orden de magnitud de las capacitancias es aplicar las fórmulas:

$$C_s = m_{s,ir} \cdot c_{s,ir} + m_{s,cu} \cdot c_{s,cu} \quad (21)$$

$$C_r = m_{r,ir} \cdot c_{s,ir} + m_{r,al} \cdot c_{s,cu} \quad (22)$$

donde la masa del acero del estator $m_{s,ir}$ es de 8 kg, la masa del cobre en el estator $m_{s,cu}$ es de 2 kg, la masa del acero en el rotor $m_{r,ir}$ es 5,4 kg y la masa del aluminio en el rotor es de 0,6 kg. Los calores específicos del acero, cobre y aluminio son $[0.50.390.9]^T$ J/(g°C) respectivamente. Aplicando (21) y (22) el vector $[C_s C_r]^T$ es igual a $[4780 \ 3240]^T$ J/°C.

Las resistencias térmicas se calcularon usando las fórmulas que propone Boglietti, Cavagnino, Lazzari, y Pastorelli, (2003), donde el cálculo de las resistencias térmicas se realiza a partir del conocimiento de las mediciones internas del motor, los materiales y constantes universales. Con esto se plantea la descomposición del motor en varios cilindros concéntricos y se calcula la resistencia radial para cada cilindro. El cuadro 2 muestra los resultados de las resistencias térmicas del modelo de la figura 7.

Cuadro 2. Valores de las resistencias térmicas obtenidas según Boglietti et al., (2003)

R_{eca}	0.5116 °C/W	Resistencia por convección forzada entre la carcasa y el ambiente
R_o	0.3063 °C/W	Resistencia por convección natural entre la carcasa y el ambiente
R_{sy1}	0.0041 °C/W	Resistencia por conducción radial de la parte baja del núcleo
R_{sy2}	0.0041 °C/W	Resistencia por conducción radial de la parte alta del núcleo
R_{st}	0.0291 °C/W	Resistencia por conducción de diente del estator
$R_{cu,ir}$	0.01796 °C/W	Resistencia por conducción entre cobre y el diente del núcleo
$R_{ew,ec}$	4.2265 °C/W	Resistencia por conducción entre devanado externo y carcasa
R_{airgap}	0.0888 °C/W	Resistencia del entrehierro
R_{shf}	37.4184 °C/W	Resistencia axial por conducción del eje
R_{sig}	0 °C/W	Resistencia entre el núcleo y la carcasa
$R_{ia,ec}$	∞ °C/W, Sin datos	Resistencia por convección entre aire interno y tapas
$R_{ew,ia}$	∞ °C/W, Sin datos	Resistencia por convección entre devanado externo y aire interno




Figura 7. Modelo térmico propuesto por Boglietti et al., (2003).

A partir del análisis del modelo de la figura 7, se plantean las ecuaciones para determinar las conductancias térmicas del modelo simplificado representado por (18).

$$G_s = \frac{1}{\left(\frac{1}{R_{cu,ir} + R_{st} + R_{sy1} + R_{sy2}} + \frac{1}{R_{ew,ec}} + \frac{1}{R_{ia,ec} + R_{ew,ia}} \right)^{-1} + \left(\frac{1}{R_0} + \frac{1}{R_{eca}} \right)^{-1}} \quad (23)$$

$$G_{sr} = \frac{1}{R_{r,ag} + R_{r,ag}} = \frac{1}{R_{airgap}} \quad (24)$$

$$G_r = \frac{1}{R_{shf} + \left(\frac{1}{R_0} + \frac{1}{R_{eca}} \right)^{-1}} \quad (25)$$

Las conductancias térmicas G_s, G_r, G_{sr} se calculan usando las tres ecuaciones anteriores y los datos del cuadro 2. Los valores calculados son $G=[4.06 \ 0.026 \ 11.26]^T \text{ W/}^\circ\text{C}$.

Análisis de resultados

El cálculo de las capacitancias y conductancias térmicas realizadas en la sección anterior responden a una aproximación que utiliza las dimensiones del motor, sus materiales y constantes físicas, etc. Por lo tanto, es esperable que existan errores dado que no se conocían algunas constantes constructivas del motor y se debieron estimar según la literatura (Boglietti et al., 2003). Los parámetros obtenidos sirven para comparar el orden de las magnitudes con los resultados del algoritmo genético. Los errores obtenidos entre los parámetros del algoritmo genético y los parámetros calculados por las ecuaciones de la (23) a la (25) se muestra en el cuadro 3.

Cuadro 3. valor absoluto del error en los Parámetros térmicos

Símbolo	Error relativo al A.G
C_s	8.8%
C_r	39.8%
G_s	2.2%
G_r	100%
G_{sr}	7.4%

Se observa que existen dos parámetros con errores altos C_r y G_r ambos relacionados con el rotor. La capacitancia del rotor obtenida por el algoritmo genético es mayor que la obtenida por la ecuación (22), esto se debe principalmente a que esta ecuación no contempla el almacenamiento de calor del aire confinado en motores sellados como el motor en estudio, por lo que si se contemplara este hecho en dicha ecuación, la capacitancia tendería a ser mayor y, por tanto, a asemejarse a la obtenida por el GA. Por otra parte la conductancia térmica del rotor obtenida por el GA indica que es prácticamente cero, lo cual se interpreta como que el calor producido por el rotor fluye a través del entrehierro y no por el eje del motor hacia el ambiente. Este resultado si concuerda por el obtenido con la ecuación (25) que da un valor de $0,026 \text{ W/}^\circ\text{C}$, sin embargo cuando se calcula el error relativo este da un valor de 100%, esto se debe a que cualquier número respecto a un valor de casi cero tendrá un error muy alto como en este caso.

El modelo obtenido por las ecuaciones (19) es alimentado con los parámetros obtenidos por el GA cuadro 1 y por los parámetros analíticos obtenidos por las ecuaciones (21) a la (25). Ambos conjuntos de parámetros generan para el mismo modelo respuestas dinámicas distintas tal y como se aprecia en la figura 8, obteniéndose unas diferencias máximas de las respuestas de temperaturas de 11°C en el trasciende y de 5°C en estado estable.

Finalmente, se rescata que el modelo térmico con los parámetros obtenidos por el GA presenta un mejor ajuste respecto a los datos experimentales $\epsilon=0.5317$, que el modelo con parámetros analíticos con ajuste de $\epsilon=50.65$, el ajuste del algoritmo genético se observa en la figura 9. Esto, como se dijo anteriormente se debe a que el algoritmo genera 80000 conjuntos de valores posibles y selecciona un conjunto con la mejor aptitud. Por lo tanto, el método para obtener los parámetros de un modelo térmico simple con algoritmos genéticos, es una opción eficiente en el sentido de que no se requiere conocer características físicas, materiales, etc., del motor en estudio.




Figura 8. Simulación de las temperaturas del rotor y estator para el modelo planteado (19) según los parámetros obtenidos por algoritmo genético y los obtenidos de forma analítica.

Agradecimiento

Se agradece a la Vicerrectoría de Investigación del Instituto Tecnológico de Costa Rica por el financiamiento brindado al proyecto SEMAT, código VIE 5402-1341-1301, así como a los asistentes vinculados a este proyecto.




Figura 9. Ajuste de temperaturas entre la medida y la estimada.

Bibliografía

- Boglietti, A., Cavagnino, A., Lazzari, M., & Pastorelli, M. (2003). A Simplified Thermal Model for Variable-Speed Self-Cooled Industrial Induction Motor. *IEEE Transactions on Industry Applications*, 39(4), 945–952. <http://doi.org/10.1109/TIA.2003.814555>
- Boglietti, A., Cavagnino, A., & Staton, D. (2008). Determination of Critical Parameters in Electrical Machine Thermal Models. *IEEE Transactions on Industry Applications*, 44(4), 1150–1159. <http://doi.org/10.1109/TIA.2008.926233>
- Boldea, I., & Nasar, S. A. (2002). *The Induction Machine Handbook*. CRC Press.
- Cho, K., & Seok, J. (2008). Induction Motor Temperature Estimation Based on High-Frequency Model of Rotor Bar. In *Industry Applications Society Annual Meeting, 2008. IAS '08. IEEE* (pp. 1–7). <http://doi.org/10.1109/08IAS.2008.208>
- Duran, M. J., & Fernandez, J. (2004). Lumped-Parameter Thermal Model for Induction Machines. *IEEE Transactions on Energy Conversion*. <http://doi.org/10.1109/TEC.2004.837272>
- Dutta, B., & Chowdhury, S. K. (2012). Steady state thermal model of TEFC induction machine. In *IEEE International Conference on Emerging Technologies and Factory Automation, ETFAPower Electronics, Drives and Energy Systems (PEDES), 2012* (pp. 1–6). Bengaluru. <http://doi.org/10.1109/PEDES.2012.6484344>
- Fraile-Mora, J. (2008). *Máquinas Eléctricas* (6th ed.). España: McGraw-Hill Interamericana de España.

- Gao, Z. (2006). *SENSORLESS STATOR WINDING TEMPERATURE ESTIMATION FOR INDUCTION MACHINES*. Georgia Institute of Technology.
- Gao, Z., Habetler, T. G., Harley, R. G., & Colby, R. S. (2005). An Adaptive Kalman Filtering Approach to Induction Machine Stator Winding Temperature Estimation Based on a Hybrid Thermal Model. *IEEE Industry Applications Conference*, 2–9. <http://doi.org/10.1109/IAS.2005.1518284>
- IEEE Standard Test Procedure for Polyphase Induction Motors and Generators. (2004). *IEEE Std 112-2004 (Revision of IEEE Std 112-1996)*, 0_1–79. <http://doi.org/10.1109/ieeestd.2004.95394>
- Kim, D. J., Choi, J. H., Chun, Y. Do, Koo, D. H., & Han, P. W. (2014). The study of the stray load loss and mechanical loss of three phase induction motor considering experimental results. *Journal of Electrical Engineering and Technology*, 9, 121–126. <http://doi.org/10.5370/jeet.2014.9.1.121>
- Kylander, G. (1995). *Thermal modelling of small cage induction motors*. Chalmers University of Technology. Retrieved from <http://publications.lib.chalmers.se/records/fulltext/1335/1335.pdf>
- Moreno, J. F., Hidalgo, F. P., & Martínez, M. D. (2001). Realisation of tests to determine the parameters of the thermal model of an induction machine. *IEE Proceedings - Electric Power Applications*. <http://doi.org/10.1049/ip-epa:20010580>
- Murillo-Soto, L. D. (2014). Aplicación informática para el monitoreo de variables eléctricas , mecánicas y térmicas en motores trifásicos de inducción. In *Latin American and Caribbean Conference for Engineering and Technology (LACCEI'2014)*. Guayaquil: EBSCO. Retrieved from <http://www.laccei.org/LACCEI2014-Guayaquil/ExtendedAbstracts/EA026.pdf>
- Okoro, O. I., Weidemann, B., & Ojo, O. (2004). An efficient thermal model for induction machines. *Conference Record of the 2004 IEEE Industry Applications Conference, 2004. 39th IAS Annual Meeting.*, 4. <http://doi.org/10.1109/IAS.2004.1348823>
- Oraee, H. (2000). A quantative approach to estimate the life expectancy of motor insulation systems. *IEEE Transactions on Dielectrics and Electrical Insulation*, 7(6), 790–796. <http://doi.org/10.1109/94.891990>
- Pillay, P., & Manyage, M. (2006). Loss of life in induction machines operating with unbalanced supplies. *IEEE Transactions on Energy Conversion*, 21(4), 813–822. <http://doi.org/10.1109/TEC.2005.853724>
- Rudolph, G. (1994). Convergence analysis of canonical genetic algorithms. *IEEE Transactions on Neural Networks*, 5, 96–101. <http://doi.org/10.1109/72.265964>
- Shenkman, a. L., & Chertkov, M. (2000). Experimental method for synthesis of generalized thermal circuit of polyphase induction motors. *IEEE Transactions on Energy Conversion*, 15(3), 264–268. <http://doi.org/10.1109/60.875491>
- Talbi, E. G. (2009). *Metaheuristics: From Design to Implementation*. *Metaheuristics: From Design to Implementation*. <http://doi.org/10.1002/9780470496916>
- Zocholl, S. E. (2004). Comparing motor thermal models. In *In 31st Annual Western Protective Relay Conference* (pp. 1–10). WA.
- Zocholl, S. E., Schweitzer, E. O., & Aliaga-Zegarra, A. (1984). Thermal Protection of Induction Motors Enhanced by Interactive Electrical and Thermal Models. *IEEE Transactions on Power Apparatus and Systems, PAS-103*(7), 1749–1755. <http://doi.org/10.1109/TPAS.1984.318678>

De: CIBEM 2017

Enviado: domingo, 14 de mayo de 2017 19:47

Para: Luis Diego Murillo Soto

Asunto: CIBEM 2017 submission 211 update

Dear authors,

we acknowledge that we received new files for your CIBEM 2017 submission. The information about this update is shown below.

Number: 211

Authors: Luis Murillo-Soto, Cindy Calderón-Arce and Geovanni Figueroa-Mata

Title: VALORACIÓN DE ÍNDICES BASADOS EN LAS PÉRDIDAS DE POTENCIA PARA LA DETECCIÓN DE FALTAS EN UN MOTOR ELÉCTRICO

Uploaded by: Luis Murillo-Soto <lmurillo@itcr.ac.cr>

Updates:

Paper/Artigo/Artículo, version 3 (5374979 bytes)

To access the new version of your submission you should log in to the CIBEM 2017 EasyChair page.

VALORACIÓN DE ÍNDICES BASADOS EN LAS PÉRDIDAS DE POTENCIA PARA LA DETECCIÓN DE FALTAS EN UN MOTOR ELÉCTRICO

Luis D. Murillo-Soto¹, Cindy Calderón-Arce², Geovanni Figueroa-Mata²

¹Escuela de Ingeniería Electromecánica, ²Escuela de Matemática
Instituto Tecnológico de Costa Rica, Cartago, Costa Rica
email: {lmurillo, ccalderon, gfigueroa} @itcr.ac.cr

Resumen

Se presenta un método alternativo para determinar condiciones de operación anómalas en un motor trifásico de inducción, basado en un conjunto de índices adimensionales, calculados a partir de sus pérdidas de potencia. Estos índices son sensibles a variaciones en las condiciones en que opera el motor y por lo tanto se valorará si, en conjunto, son capaces de discriminar entre un desbalance de voltaje, un subvoltaje o una variación térmica, entre otros. En este trabajo se desarrollan las ecuaciones necesarias para calcular las pérdidas eléctricas que permiten el cálculo de los índices propuestos. Es importante destacar que estos índices unifican la interpretación de variables eléctricas, mecánicas y térmicas con la intensidad de su utilización en el diseño de un sistema automático de detección de faltas que opere en tiempo real, por medio de un prototipo basado en redes neuronales. Adicionalmente, se describen los experimentos realizados a un motor trifásico de inducción de dos caballos de fuerza, 230 Voltios - 60 Hertz, el banco de pruebas construido y en la parte final del trabajo se representa de forma gráfica la variabilidad de los índices ante distintas condiciones anormales, lo que permite valorar su sensibilidad y relación con las faltas asociadas.

Palabras claves: Índices de pérdidas, detección de faltas, motor de inducción, redes neuronales

1. Introducción

El motor eléctrico es un convertidor no ideal de energía eléctrica a mecánica, los motores modernos de alta eficiencia alcanzan valores de conversión de energía de hasta 95% para potencias superiores a los 50 caballos de fuerza (hp) y para motores con potencias no menores de 3 hp sus eficiencias son superiores a un 90%. La deficiente conversión de energía provoca el incremento de temperatura interna en la máquina tal y como lo explican los modelos térmicos descritos por [1], [2], [3], [4]. La ecuación (1) muestra que un incremento de las pérdidas en la máquina provoca un decrecimiento de la eficiencia de forma proporcional.

$$\eta = 1 - \frac{P_{loss}}{P_{in}} \quad (1)$$

donde η es la eficiencia y P_{loss} , P_{in} son las potencias por pérdidas y potencia de entrada del motor, respectivamente. El mínimo cambio en las pérdidas de la máquina no solo afecta la eficiencia, sino que esa energía adicional desperdiciada es convertida en calor. Medir la temperatura interna no es suficiente para explicar de dónde proviene ese calor.

Se propone utilizar índices que relacionan los distintos tipos de pérdidas de potencia del motor con el fin de utilizarlos para determinar el fallo¹ o la alteración en la condición de operación del motor, es decir, un fallo en la máquina repercute en su eficiencia y por lo tanto en los índices propuestos. Este trabajo se organiza de la siguiente forma: la sección II hace una descripción de las pérdidas del motor y los índices propuestos. En la sección III se muestra el banco de pruebas y las pruebas realizadas al motor, la sección IV muestra los experimentos realizados utilizando los cinco índices para la construcción de un prototipo de sistema de diagnóstico basado en redes neuronales artificiales, además se realiza un análisis de la variabilidad de los índices bajo condiciones tanto normales como anormales del motor, tomando en cuenta la sensibilidad y similitud entre los índices propuestos para identificar y categorizar faltas en el motor. La sección V presenta un análisis de resultados general y, finalmente, la sección VI las conclusiones.

2. Pérdidas del motor de inducción y definición de índices

Las potencias por pérdidas son resultado de un deficiente proceso de conversión de energía

eléctrica a mecánica. Así, la potencia total de pérdida se calcula como la diferencia entre la potencia de entrada P_{in} y la de salida P_{out} , tal y como se muestra en la ecuación (2)

$$P_{loss} = P_{in} - P_{out} = P_s + P_r + P_{mis} \quad (2)$$

donde P_s representa la pérdida del estator, P_r la del rotor y P_{mis} las potencias mecánica y misceláneas. Además, la potencia por pérdidas del estator P_s se calcula por medio de la ecuación (3), donde P_{cs} es la potencia de pérdida por efecto Joule en los devanados estatóricos y P_{ns} la potencia por pérdidas en el núcleo debido a corrientes parásitas e histéresis.

$$P_s = P_{cs} + P_{ns} \quad (3)$$

$$P_{cs} = R_s(I_a^2 + I_b^2 + I_c^2)(1 + 0.00389(\Delta\theta)) \quad (4)$$

La potencia P_{cs} se calcula como en la ecuación (4), donde R_s es la resistencia estatórico medida a la temperatura ambiente, los términos I_a , I_b , I_c son las corrientes por fase, el término $\Delta\theta$ representa la diferencia de temperatura del devanado estatórico y la temperatura ambiente.

Por otro lado, las potencias por pérdidas del rotor P_r se determinan según la ecuación (5), donde s es un número adimensional que se calcula según la ecuación (6), n_{scr} es la velocidad sincrónica y n_{mec} es la velocidad mecánica del motor

$$P_r = (P_{in} - P_{cs} - P_{ns})s \quad (5)$$

$$s = \frac{n_{scr} - n_{mec}}{n_{scr}} \quad (6)$$

Luego, la pérdida P_{mis} se puede estimar como en la ecuación (7)

$$P_{mis} = \chi(P_{in} - P_{out}) \quad (7)$$

donde χ oscila entre [0, 0.11] según datos de [5], se puede calcular de forma experimental por medio de las pérdidas mecánicas y misceláneas.

Dado que las ecuaciones (3) y (5) dependen de P_{ns} , es necesario estimarla. Para ello, se sustituye (3), (5) y (7) en (2) para obtener la potencia del núcleo P_{ns} en términos de parámetros medidos

$$P_{ns} = \frac{(1 - s - \chi)P_{in} - (1 - s)P_{cs} - (1 - \chi)P_{out}}{(1 - s)} \quad (8)$$

¹ Entiéndase falta y fallo como equivalentes, en el contexto de este trabajo.

Nuevamente, al sustituir (8) en (3) y (5) se obtienen expresiones que solamente dependen de las mediciones realizadas. De esta forma las expresiones para P_s y P_r , tomando $\chi = 0$, son aproximadas por las expresiones en (9) y (10).

$$P_s \approx P_{in} - \frac{P_{out}}{(1-s)} \quad (9)$$

$$P_r \approx s \frac{P_{out}}{(1-s)} \quad (10)$$

2.1. Definición de índices

En esta sección se definen cinco índices calculados por medio de las pérdidas del motor expuestas anteriormente. En conjunto, estos índices logran determinar si hay cambios en la carga del motor, alteraciones en el voltaje de alimentación o un calentamiento por pobre ventilación.

Los índices que se proponen son

$$I_{cs} = \frac{P_{cs}}{P_{loss}} \quad (11)$$

$$I_{ns} = \frac{P_{ns}}{P_{loss}} \quad (12)$$

$$I_r = \frac{P_r}{P_{loss}} \quad (13)$$

$$I_{rcs} = \frac{P_r}{P_{cs}} \quad (14)$$

$$I_{rs} = \frac{P_r}{P_s} \quad (15)$$

El índice I_{cs} establece una relación entre las pérdidas que ocurren por efecto Joule entre el devanado estatórico y las pérdidas totales, este índice varía de acuerdo a los cambios en el voltaje de alimentación. A su vez I_{ns} calcula la relación entre la potencia disipada en el núcleo de la máquina y la total desperdiciada. El índice I_r relaciona las pérdidas del rotor entre el total de pérdidas. Los índices I_{rcs} y I_{rs} buscan establecer las relaciones específicas entre dos tipos de pérdidas de potencia, el primer caso establece la relación entre potencias perdidas en el rotor y cobre del estator y el segundo índice relaciona las pérdidas del rotor y el estator.

3. Banco de pruebas

El banco de pruebas para motores trifásicos que se construyó se compone de un generador de corriente directa de 5 kW y un banco de resistencias de 7 kW. El banco posee tres auto transformadores

monofásicos conectados en estrella para provocar bajos y altos voltajes de alimentación así como desbalances. En la figura 1 se muestra una fotografía parcial del banco de pruebas implementado.




Figura 1: Banco de pruebas implementado. Tomado de [6]

Para interconectar el banco de pruebas con el sistema de adquisición de datos, se desarrolló una aplicación informática [6] que gestiona el banco de pruebas y somete los motores a experimentos controlados en donde se definen los parámetros de la prueba. La aplicación controla los estímulos del motor (carga del motor, tiempos de encendido o apagado), monitorea su reacción y se registra todas las variables de interés.




Figura 2: Interfaz gráfica de los índices en tiempo real

El programa implementa, en tiempo real, el cálculo de los cinco índices propuestos tal como se muestra en la figura 2. Cada segundo se publica la media móvil de los últimos diez valores con la finalidad de suavizar las curvas. El código LabVIEW del cálculo de los índices se muestra en la figura 3. Cuando la prueba finaliza, la aplicación guarda, en archivo de texto, todas las variables eléctricas, mecánicas y los índices propuestos. Así, el archivo contiene los índices calculados en cada segundo durante la prueba.




Figura 3: Interfaz de índices en LabVIEW

3.1 Pruebas realizadas

El motor en estudio es de la marca Baldor modelo M3558 de 2hp, 230 V, 60 Hz. Los fallos a los que se somete el motor se realizaron durante su transitorio térmico. Un buen modelo que aproxima este comportamiento lo plantea [7], indicando que la respuesta térmica del motor se modela como un sistema de primer orden cuyo resultado se presenta en la ecuación (16).

$$\theta = P_{loss} \cdot R_{th} \cdot \left(1 - e^{\frac{-t}{R_{th}C_{th}}}\right) + \theta_A \quad (16)$$

Donde θ y θ_A son las temperaturas interna y la ambiental respectivamente, el término P_{loss} representa la totalidad de pérdidas del motor como se mostró en la sección 2, el término R_{th} representa una resistencia térmica equivalente del motor, C_{th} representa la capacitancia térmica equivalente del motor y el término t representa el tiempo.

El estado estable de la máquina sin fallos asociados se alcanza en 5τ , donde $\tau = R_{th}C_{th}$. Sin embargo, para efectos experimentales se considera que se alcanza el equilibrio térmico cuando dos cambios consecutivos de la temperatura interna, separados por un lapso de cinco minutos, no varía en menos de un grado centígrado, esto es

$$|\theta_t - \theta_{t-5min}| \leq 1^\circ C \quad (17)$$

Para el motor en cuestión, el transitorio térmico experimental se alcanzó aproximadamente en los 8000 segundos bajo el criterio anterior. Durante todo el transitorio térmico se somete el motor a una condición anormal, ya sea subvoltaje, desbalance o un cobertor que simula poca ventilación, dichas condiciones se denominan fallos tipo uno, dos o tres, respectivamente, la tabla 1 muestra la descripción de los mismos.

De forma similar al 100% de carga, se realizaron pruebas al 75% y al 50% de carga, en el código de la prueba se sustituye el término C100 por C75 y C50, según corresponda.

Tabla 1: Resumen de condiciones de fallo al 100% de carga

Fallo	Carga	Voltaje (V)	Desbalance.	Cobertor.	Código
Sin fallo	100%	230	<1%	No	C100
Tipo 1	100%	200	<1%	No	C100V115 ²
Tipo 2	100%	230	3%	No	C100D3
Tipo 3	100%	230	<1%	Si	C100Cobertor

La figura 4 muestra el comportamiento de la temperatura del motor ante los tres tipos de fallos indicados anteriormente y la curva de funcionamiento normal, al 100% de carga. En dicha figura se puede observar que la diferencia entre el comportamiento de cada fallo y el comportamiento normal es mínima, por lo que detectar alguno de esos fallos en el motor no es una tarea sencilla.




Figura 4: Comportamiento térmico del motor con fallos al 100% de carga

4. Experimentos realizados y valoración de índices

Esta sección muestra los experimentos realizados y sus resultados con el fin de determinar la viabilidad de los índices para el diagnóstico de fallos. Primeramente, se utilizó una red neuronal artificial como prototipo de un sistema de diagnóstico automático. Posteriormente, se utilizan mapas autoorganizados para analizar si los índices poseen redundancia. Finalmente, se realiza un análisis gráfico de los índices para distintas pruebas en donde se confirma que existe duplicidad en la información que aportan algunos indicadores.

4.1 Redes neuronales

Una red neuronal artificial es un modelo simplificado del sistema neuronal humano [8],[9]. La unidad más simple de una red neuronal es la neurona artificial, la cual posee dos etapas, la primera suma los productos de la entrada $I(j)$ por el

² 200V $\approx 1.73 \cdot 115V$

factor de su peso de arco $W(j)$, luego se le suma un factor de polarización llamado bias b .

La segunda etapa consiste en utilizar el resultado de la suma anterior y realizar la activación de la neurona mediante una función de transferencia. Existen varios tipos de funciones de activación [10], entre ellas *Sigmoid* (a), *Logsig* (a), *Purelin* (a), para este trabajo se utiliza la llamada *Tansig* (a). La figura 5 muestra una representación gráfica del modelo descrito anteriormente y la ecuación (18) su representación algebraica.




Figura 5: Neurona artificial

$$a = \sum_{j=1}^n [W(j)I(j)] + b \quad (18)$$

$$y = \text{Tansig}(a) = \frac{2}{1 + e^{-2a}} - 1$$

4.1.1 Clasificador basado en red neuronal

Se diseñó una red neuronal artificial (RNA) tipo “feedforward” para decidir si un motor eléctrico presenta alguno de los tres tipos de fallos descritos en la tabla 1 o si se encuentra en funcionamiento normal. La red posee diez entradas distribuidas de la siguiente forma: cinco entradas una para cada índice calculado en un instante específico y las otras cinco entradas para los valores anteriores a las muestras actuales. La red posee una capa oculta de diez neuronas y una capa de salida con cuatro neuronas, una por cada fallo más la salida para el funcionamiento normal. Cada una de las neuronas son idénticas y poseen el funcionamiento de la ecuación (18). Las neuronas de la capa oculta se definieron con la siguiente regla heurística

$$\text{Neuronas} \geq \frac{N_e + N_s}{2} \quad (19)$$

donde N_e y N_s representa cantidad de entradas y salidas respectivamente. Se definieron diez neuronas ocultas con el fin de incrementar la exactitud y disminuir el error cuadrático medio.

La figura 6 muestra la descripción anterior, los rombos representan los puertos de entrada y el término Z^{-1} indica que esa entrada específica ingresa la muestra anterior del *dataset*, W_1 representa la matriz de pesos de la capa oculta, esta matriz posee dimensión 10×10 y la matriz de pesos de las neuronas de salida se representa como W_2 y posee una dimensión de 4×10 . La salida vectorial F de la red neuronal queda descrita por la ecuación (20).

$$F = \text{Tansig}(W_2 \cdot \text{Tansig}(W_1 \cdot I + b_1) + b_2) \quad (20)$$

donde I es el vector de entradas, b_1 es el vector de bias de las neuronas de la capa oculta de tamaño 10×1 y b_2 es el bias de las neuronas de la capa de salida que posee un tamaño 4×1 .




Figura 6: RNA para clasificación de fallos de un motor eléctrico

4.1.2 Entrenamiento de red

A fin de ajustar los pesos almacenados en las matrices W_1 , W_2 y en los vectores b_1 y b_2 se realizaron varios entrenamientos supervisados de la red. El mejor resultado se logró con el algoritmo Levenberg–Marquardt con aprendizaje basado en gradiente descendente y momento. La tasa de aprendizaje usada fue de 0.01 y la constante del momento usada fue de 0.9.

Tal y como se mencionó, el motor en estudio se expuso a los fallos descritos en la tabla 1 y se almacenaron en cada segundo, los cinco índices

definidos en la sección 2.1. El fallo a que se somete el motor está presente durante el transitorio térmico.

Para construir el conjunto de datos de prueba (*dataset*) se unificaron las tres pruebas y la prueba en funcionamiento sin fallo, dicho *dataset* posee más de 36000 registros. Posteriormente, se muestreó de forma uniforme cada 180 muestras y se construyó el *dataset* definitivo que posee 200 registros, cada 50 registros corresponde a una prueba específica. Es importante señalar que los 50 registros calculan los índices en distintos instantes del transitorio térmico del motor.




Figura 7: Error cuadrático medio vs entrenamiento y validación

Con la arquitectura de la red neuronal y el *dataset* definitivo se procedió, primeramente, a realizar el entrenamiento supervisado con el algoritmo de retropropagación. La retropropagación es una técnica en la que la red es entrenada con un conjunto de entradas y salidas conocidas y para cada iteración del algoritmo, los pesos de las matrices \mathbf{W} y \mathbf{b} son auto ajustados, con el fin de minimizar el error entre la salida actual y su valor esperado. Este ajuste se aplica desde las capas de salida hasta las capas de entrada, de ahí el nombre de retropropagación. Para

el presente trabajo este algoritmo no brindó los resultados esperados dado que el error cuadrático medio presentó valores alrededor de 0.22, considerado alto por los autores. Por esta razón se optó por utilizar el algoritmo Levenberg–Marquardt que se utiliza para minimizar funciones por mínimos cuadrados no lineales [9].

La figura 7 muestra la gráfica de error cuadrático medio (mse) versus la cantidad de entrenamientos completos con el *dataset* definitivo. Se observa un mse de 0.03197 en veintiocho *epochs*.

Una vez entrenada la red, se construyó un segundo *dataset* con la finalidad de probarla. Se definió un valor umbral de aceptación de fallos mayor a 0.85. Así, cuando la RNA arroja, en una salida, un valor superior al umbral se considera que la red ha detectado una condición particular, ya sea funcionamiento normal o fallo tipo uno, dos o tres.

Un valor muy alto del umbral hace que el sistema de clasificación genere muchos falsos negativos, es decir, que no detecte cuando hay fallos específicos. Por otro lado, con bajos valores del umbral se corre el riesgo de generar falsos positivos, es decir que el sistema indique que hay un fallo específico cuando en realidad no existe.

La figura 8 muestra los resultados de la RNA con el segundo *dataset* construido. Al igual que el primero, este *dataset* posee 200 registros, y cada 50 muestras corresponde a un tipo de fallo, las primeras 50 muestras pertenecen al fallo tipo uno, los siguientes 50 registros al fallo tipo dos y así sucesivamente. Se señala nuevamente que las 50 muestras para cada prueba realizada poseen un espaciamiento temporal uniforme de 180 segundos.




Figura 8: Clasificación por índices

Esto a su vez implica que los cinco índices fueron calculados durante el régimen transitorio de temperatura.

Además, se observa en la figura 8 que, con los índices propuestos, la RNA detecta los fallos tipo 1 en cualquier instante del transitorio térmico en que ocurra. Esto concuerda con la primera gráfica de correlación de la figura 9, que muestra la correlación del resultado de la red versus el valor real. Para este caso el valor de correlación es de $R = 0.98889$.

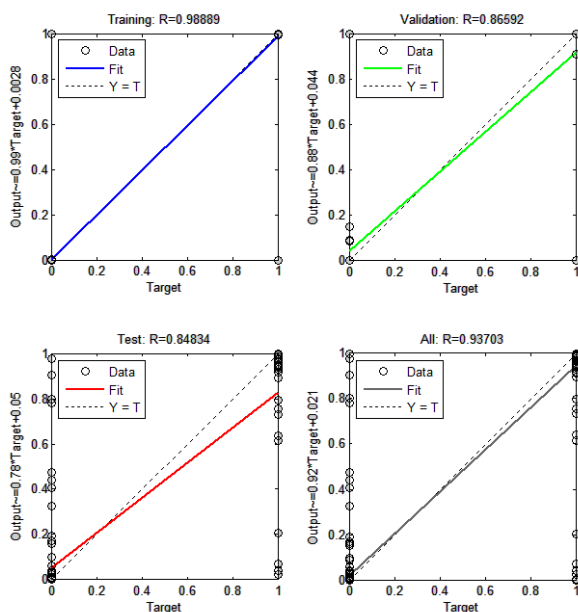


Figura 9: Correlaciones de los resultados de la RNA vs el valor real

Para la prueba del motor con el fallo inducido dos, este presenta tanto falsos negativos como falsos positivos. Este se ve reflejado en el índice de correlación de resultados versus valores reales que es de $R = 0.8483$. Para las pruebas tipo tres, la RNA no diagnóstica algunos casos de este fallo cuando el motor lo sufre (falso negativo), su índice de correlación es de 0.86592. Finalmente, cuando la red no presenta fallo la RNA logra determinar la gran mayoría de los casos, el índice de correlación es de 0.93703.

4.2 Mapas autoorganizados

Un mapa autoorganizado (SOM) es un tipo de red neuronal artificial, que se entrena utilizando un aprendizaje no supervisado para producir una representación discreta del espacio de las muestras de entrada [8], [9]. Organizándolas o agrupándolas de acuerdo a patrones o características comunes, tomando en cuenta tanto la competitividad, como la cooperatividad entre dichas muestras. En la etapa de competitividad, para cada muestra $I(j)$ se selecciona la neurona con la distancia euclídea más

pequeña, según la ecuación (21), donde cada neurona representa una región en el espacio de entrada.

$$i^* = \operatorname{argmin}_i \|w_i - I(j)\| \quad (21)$$

La neurona con vector de pesos más similar a la entrada es la ganadora. Por otro lado, en la etapa de cooperatividad, cada neurona se compara con sus neuronas vecinas, en la cual tanto el vector de pesos de la neurona ganadora es actualizado, por medio de una regla de actualización Δw_i , como el mallado de su vecindario. Para ello se utiliza una función Gaussiana de vecindad Λ , centrada en la neurona ganadora y decreciente respecto a la distancia de la neurona ganadora.

$$\Delta w_i = \alpha \Lambda(i, i^*, \sigma_\Lambda(t))(I(j) - w_i)$$

$$\Lambda(i, i^*) = \exp\left(-\frac{\|r_i - r_{i^*}\|^2}{2\sigma_\Lambda^2}\right) \quad (21)$$

donde r_i y r_i^* representan los nodos del mallado discreto con una topología regular [11].

4.2.1 Similitud de índices con pruebas al 100% de carga por medio de SOM

Con la finalidad de analizar y detectar similitudes entre el comportamiento de los cinco índices definidos en la sección 2.1, se entrenó un SOM de 4×4 neuronas, con una tasa de aprendizaje $\alpha = 0.02$ y desviación estándar $\sigma_{\Lambda} = 0.45$, tomando como entradas los valores de los cinco índices en las pruebas definidas en la tabla 1.

La figura 10 muestra los resultados del entrenamiento del mapa autoorganizado con una malla de 4×4 , donde las neuronas en negro indican que no hay valores asociados a las mismas. Además, la escala de colores amarillo-rojo indica que entre más intenso u oscuro es el tono hay más valores asociados a la neurona, el amarillo representa menor intensidad y el rojo mayor intensidad.

Así, según el patrón obtenido con el SOM, los cinco índices propuestos se pueden organizar en tres grupos

$$\begin{array}{ccc} \bullet & I_{cs} & \bullet & I_{ns} & \bullet & I_r \\ & I_{rs} & & I_{rcs} & & \end{array}$$

suponiendo que mapas similares indican características y comportamiento similares de los

índices. Por lo que se podría reducir la cantidad de índices a solamente tres, uno por grupo

- I_{rs}
- I_{rcs}
- I_r

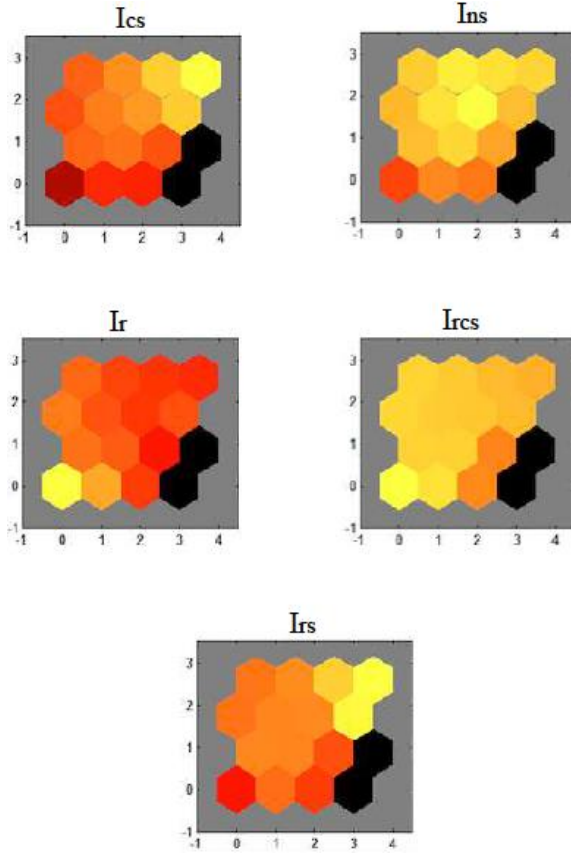


Figura 10: SOM de 4×4

Tomando los tres anteriores como representativos o significativos, y además suficientes, para entrenar la RNA de la sección 4.1. y así intentar describir el comportamiento con fallo del motor.

4.3 Variabilidad de índices

Siguiendo los resultados obtenidos por medio del SOM para el caso de pruebas al 100% de carga, se realizó un análisis de los índices por tipo de fallo, de manera independiente, y además se generalizó para pruebas al 75% y al 50% de carga. Con el objetivo de validar la agrupación y selección de índices realizada en la sección 4.2.1. y además analizar la variación de los mismos por tipo de prueba (100%, 75% y 50% de carga) y por tipo de fallo (condiciones normales del motor, subvoltaje, desbalance y cobertor).

En las figuras 11 se muestra la distribución de los valores de cada índice bajo condiciones nominales del motor y para cada uno de los tres fallos con los

que se entrenó la RNA de la sección 4.1. (subvoltaje con 200V, 3% de desbalance y cobertor) y además se analizó un caso más de desbalance al 4%.

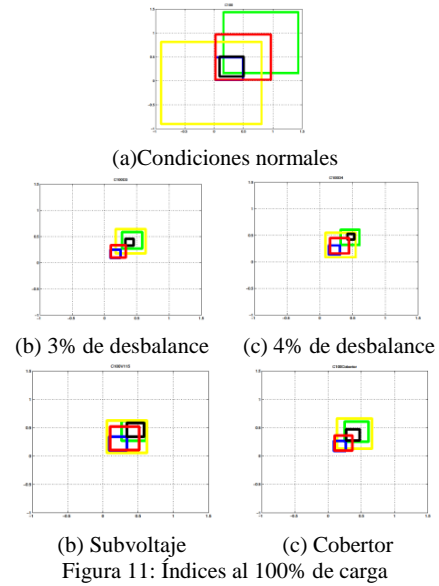


Figura 11: Índices al 100% de carga
: I_{cs} —: I_r —*: I_{ns} —*: I_{rcs} —*: I_{rs}

Tomando como referencia el valor de los índices en el tiempo y en cada una de las pruebas de manera independiente, cada color representa un índice y cada uno de los recuadros está centrado en la media de los valores de cada índice, según corresponda. Por lo que se puede observar la variación de cada índice respecto a su media y respecto a la variación de los demás índices en cada una de las pruebas.

La figura 11 muestra como los recuadros en azul, negro y rojo mantienen un patrón similar, en rango, en cada una de las pruebas, en contraposición a los recuadros verde y amarillo que presentan una variación más marcada en sus posiciones de una prueba a otra. Por otro lado, se puede observar como el par de recuadros amarillo-negro se complementan en dimensión y el amarillo siempre contiene al negro. Asimismo el par verde-rojo siempre se traspone de la misma manera, con una intersección significativa entre ellos.




Figura 12: Índices al 100% de carga
: I_{cs} —: I_r —*: I_{ns} —*: I_{rcs} —*: I_{rs}

Además, la figura 12 muestra los índices al 100% de carga por medio de una representación lineal, donde el centro de cada franja de color está dado por la media de cada índice en el tiempo, según corresponda. Con lo que es posible reafirmar lo observado en la figura 11.

Los resultados anteriores coinciden con los obtenidos por medio del SOM en la figura 10, dado que en el mapa autoorganizado se toman en cuenta los índices de manera conjunta, en condiciones nominales y con los tres tipos de fallos (subvoltaje, desbalance y cobertor) para realizar su representación gráfica. Ubicando a I_{CS} y a I_{RS} bajo un mismo patrón de comportamiento, lo mismo para I_{NS} y I_{RCS} , y categorizando los índices en tres grupos.

Así, tomando como referencia un índice por grupo, I_r , I_{RCS} y I_{RS} son suficientes para entrenar la RNA de la sección 4.1., utilizándola para caracterizar el comportamiento del motor y ubicarlo en alguno de los cinco estados analizados: condición nominal del motor, subvoltaje con 200V, 3% de desbalance, 4% de desbalance y cobertor, tal y como se muestra en la figura 13.






Figura 13: Índices representativos al 100% de carga

$$*: I_r - *: I_{RCS} - *: I_{RS}$$

Generalizando los resultados anteriores para los casos al 75% y al 50% de carga, se toman en cuenta las pruebas en condiciones nominales del motor, con fallo tipo 1 (subvoltaje con 200V) y fallo tipo 3 (cobertor) al 75% de carga, ver figuras 14-15-16.



(a)Condiciones normales



(b) Subvoltaje

(c) Cobertor

Figure 14: Índices al 75% de carga

$$*: I_{CS} - *: I_r - *: I_{NS} - *: I_{RCS} - *: I_{RS}$$




Figura 15: Índices al 75% de carga

$$*: I_{CS} - *: I_r - *: I_{NS} - *: I_{RCS} - *: I_{RS}$$





Figura 16: Índices representativos al 75% de carga

$$*: I_r - *: I_{RCS} - *: I_{RS}$$

Para el caso de 50% de carga, se toman en cuenta las pruebas en condiciones nominales del motor, con fallo tipo 1 (subvoltaje con 200V) y con fallo tipo 2 (3% de desbalance), ver figuras 17-18-19.



(a)Condiciones normales




Figure 17: Índices al 50% de carga




Figura 18: Índices al 50% de carga




Figure 19: Índices representativos al 50% de carga

: I_r —: I_{RCS} —*: I_{RS}

Similarmente al caso con 100% de carga, en las figuras 14-15 y 17-18 se puede observar como la complementariedad del par de índices $I_{NS} - I_{RCS}$ (amarillo-negro) y el patrón de comportamiento del par $I_{CS} - I_r$ (verde-azul) se mantiene para los casos al 75% y al 50% de carga, según corresponda. Así, en las figuras 16 y 19 se muestra la representación gráfica lineal de los índices que se toman como representativos para entrenar la RNA de la sección 4.1. e intentar caracterizar y categorizar el funcionamiento del motor, ahora al 75% y al 50% de carga.

5. Análisis de resultados

Los resultados de la RNA muestran que los índices propuestos logran discriminar los fallos inducidos al motor durante su transitorio térmico con 100% de carga. Es decir estos índices son capaces de operar en régimen transitorio como en régimen

estable, lo que permite ser utilizados e implementados en el diagnóstico en tiempo real de los motores eléctricos.

Además, los resultados que arroja la RNA pueden ser fácilmente mejorados si se realizan acciones como

- Aumentar al tamaño del **dataset** con pruebas realizadas en otros momentos.
- Aumentar la cantidad de las capas ocultas de la RNA y/o neuronas en cada capa.
- Incrementar las entradas de la RNA retardadas, es decir, agregar entradas con doble retardo Z^{-2} para cada índice.
- Explorar el rendimiento de otros algoritmos de entrenamiento adaptativos / evolutivos.
- Realizar estudios más detallados variando los parámetros de inicio de los algoritmos.
- Explorar otras topologías de redes neuronales tales como RNA dinámicas, etc.

Por otro lado, el análisis en la similitud y variación de los índices realizado por medio de SOM indica que es suficiente con tomar solamente tres índices, dado que es posible agruparlos en tres grupos de acuerdo a sus patrones de comportamiento en el tiempo, bajo tres porcentajes de carga (100, 75 y 50) y ante distintos tipos de fallo (subvoltaje, desbalance y cobertor). Así, se toman $I_r - I_{RCS} - I_{RS}$ como índices representativos o significativos para entrenar la RNA, categorizar el comportamiento del motor en el tiempo y así detectar algunos de los fallos definidos en la tabla 1.




Figura 20: Índices representativos

: I_r —: I_{RCS} —*: I_{RS}

En la figura 20 se muestra el resumen de los índices representativos, en todos los casos presentados en la sección 4.3., donde se puede notar que dichos índices pueden ser capaces de discriminar no solo por tipo de fallo sino que también por porcentaje de carga.

6. Conclusiones

En este trabajo se valoraron cinco índices basados en las distintas pérdidas de motor con la intención de diagnosticar fallos específicos en la máquina. Se realizó un análisis teórico de sensibilidad para observar si los índices son capaces de diagnosticar nueve tipos de fallos distintos. Se requiere realizar más análisis al respecto pero se vislumbra que los índices en conjunto pueden mapear distintos fallos que afectan la máquina.

La viabilidad de utilizar los índices, para constituir un sistema que diagnostique fallos en tiempo real, se ha demostrado utilizando una red neuronal artificial entrenada con los índices calculados en distintos instantes del régimen transitorio. Esto permite que cuando un fallo particular aparezca, ya sea en régimen transitorio o estable, el sistema con pocas muestras sea capaz de determinar el tipo de fallo que afecta al motor.

Agradecimientos

Se agradece a la Vicerrectoría de Investigación y Extensión del Tecnológico de Costa Rica por el apoyo brindado al proyecto VIE 5402-1801-0505.

Un especial agradecimiento al Ing. Osvaldo Guerrero-Castro por suministrar el *dataset* de los datos.

Referencias

[1] A. Boglietti, A. Cavagnino, M. Lazzari, and M. Pastorelli, "A Simplified Thermal Model for Variable-Speed Self-Cooled Industrial Induction Motor," *IEEE Transactions on Industry Applications*, vol. 39, no. 4, pp. 945–952, 2003.

[2] M. Duran and J. Fernandez, "Lumped Parameter Thermal Model for Induction Machines," 2004.

[3] G. Figueroa-Mata and L. D. Murillo-Soto, "Algoritmo bioinspirado aplicado a la estimación de los parámetros de un modelo térmico para un motor trifásico de inducción," in *12^o Congresso iberoamericano de engenharia mecanica (CIBIM XII)*, (Guayaquil), 2015.

[4] L. D. Murillo-Soto, G. Figueroa-Mata, and O. Guerrero-Castro, "Identificación de parámetros de un modelo térmico para un motor trifásico de inducción usando algoritmos genéticos," *Revista Tecnología en Marcha*, vol. 29, no. 5, pp. 25–41, 2016.

[5] W. Cao, "Comparison of IEEE 112 and new IEC standard 60034-2-1," *Energy Conversion, IEEE Transactions on*, vol. 24, no. 3, pp. 802–808, 2009.

[6] L. D. Murillo-Soto, "Aplicación informática para el monitoreo de variables eléctricas, mecánicas y térmicas en motores trifásicos de inducción," in *Latin American and Caribbean Conference for Engineering and Technology (LACCEI'2014)*, (Guayaquil), EBSCO, 2014.

[7] S. E. Zocholl, "Comparing motor thermal models," in *In 31st Annual Western Protective Relay Conference*, (WA), pp. 1–10, Schweitzer Engineering Laboratories, Inc., 2004.

[8] R. Lippmann, "An introduction to computing with neural nets," *IEEE Assp magazine*, vol. 4, no. 2, pp. 4–22, 1987.

[9] S. S. Haykin, S. S. Haykin, S. S. Haykin, and S. S. Haykin, *Neural networks and learning machines*, vol. 3. Pearson Upper Saddle River, NJ, USA, 2009.

[10] M. Dorofki, A. H. Elshafie, O. Jaafar, O. A. Karim, and S. Mastura, "Comparison of artificial neural network transfer functions abilities to simulate extreme runoff data," *International Proceedings of Chemical, Biological and Environmental Engineering*, vol. 33, pp. 39–44, 2012.

[11] M. M. Van Hulle, *Self-organizing Maps*, pp. 585–622. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012.

De: Alexa Ramirez

Enviado: miércoles, 17 de mayo de 2017 11:13

Para: Luis Diego Murillo Soto

CC: Ana Ruth Vílchez Rodríguez; Dagoberto Arias Aguilar

Asunto: Acuse recibo de artículo "DETECCIÓN DE FALTAS EN MOTORES ELECTRICOS CON BASE EN INDICES DE POTENCIAS Y REDES NEURONALES"

Estimado Luis Diego,

Gracias por el interés de publicar en la revista Tecnología en marcha. En las próximas semanas su documento será enviado a revisión de experto, de ser aprobado se estaría publicando en el número 31-1 correspondiente al periodo enero-marzo del próximo año.

Cualquier otra duda o consulta quedo a la orden.

Saludos cordiales,

Ing. Alexa Ramírez Vega

Editora Técnica Revistas Científicas

Encargada Portal de Revistas TEC

Instituto Tecnológico de Costa Rica

Tel. (506)2550-2336

Email. alramirez@itcr.ac.cr

<http://revistas.tec.ac.cr>



DETECCIÓN DE FALTAS EN MOTORES ELECTRICOS CON BASE EN INDICES DE POTENCIAS Y REDES NEURONALES.

Luis D. Murillo-Soto¹, Cindy Calderón-Arce², Geovanni Figueroa-Mata²

Resumen

Se presenta un método alternativo para determinar condiciones de operación anómalas en un motor trifásico de inducción, basado en un conjunto de índices adimensionales, calculados a partir de sus pérdidas de potencia. Estos índices son sensibles a variaciones en las condiciones en que opera el motor y por lo tanto se valorará si, en conjunto, son capaces de discriminar entre un desbalance de voltaje, un subvoltaje o una variación térmica, entre otros. En este trabajo se desarrollan las ecuaciones necesarias para calcular las pérdidas eléctricas que permiten el cálculo de los índices propuestos. Es importante destacar que estos índices unifican la interpretación de variables eléctricas, mecánicas y térmicas con la intención de su utilización en el diseño de un sistema automático de detección de faltas que opere en tiempo real, por medio de un prototipo basado en redes neuronales. Adicionalmente, se describen los experimentos realizados a un motor trifásico de inducción de dos caballos de fuerza, 230 Voltios - 60 Hertz, el banco de pruebas construido y en la parte final del trabajo se representa de forma gráfica la variabilidad de los índices ante distintas condiciones anormales, lo que permite valorar su sensibilidad y relación con las faltas asociadas.

Abstract

We present an alternative method to determine anomalous operating conditions in a three-phase induction motor, based on a set of dimensionless indices, they calculated from their power losses. These indices are sensitive to variations in the conditions under which the motor operates and will therefore be assessed if, on the whole, they are capable of discriminating between an unbalance of voltage, under-voltage or a thermal variation, among others. In this work the equations necessary to calculate the electrical losses that allow the calculation of the proposed indexes are developed. It is important to note that these indices unify the interpretation of electrical, mechanical and thermal variables with the intention of using them in the design of an automatic fault detection system that operates in real time, through a prototype based on neural networks. In addition, experiments are carried out on a three - phase two - horsepower induction motor, 230 Volt - 60 Hertz, the testbed constructed and the final part of the work graphically depicts the variability of the indices under different conditions Abnormal, which makes it possible to assess their sensitivity and relation to the associated faults.

Palabras claves: Índices de pérdidas, detección de faltas, motor de inducción, redes neuronales

¹Escuela de Ingeniería Electromecánica, ²Escuela de Matemática

Instituto Tecnológico de Costa Rica, Cartago, Costa Rica

email:{lmurillo, ccalderon, gfigueroa} @itcr.ac.cr

1. Introducción

El motor eléctrico es un convertidor no ideal de energía eléctrica a mecánica, los motores modernos de alta eficiencia alcanzan valores de conversión de energía de hasta 95% para potencias superiores a los 50 caballos de fuerza (hp) y para motores con potencias no menores de 3 hp sus eficiencias son superiores a un 90%. La deficiente conversión de energía provoca el incremento de temperatura interna en la máquina tal y como lo explican los modelos térmicos descritos por [1], [2], [3], [4]. La ecuación (1) muestra que un incremento de las pérdidas en la máquina provoca un decrecimiento de la eficiencia de forma proporcional.

$$\eta = 1 - \frac{P_{loss}}{P_{in}} \quad (1)$$

donde η es la eficiencia y P_{loss} , P_{in} son las potencias por pérdidas y potencia de entrada del motor, respectivamente. El mínimo cambio en las pérdidas de la máquina no solo afecta la eficiencia, sino que esa energía adicional desperdiciada es convertida en calor. Medir la temperatura interna no es suficiente para explicar de dónde proviene ese calor.

Se propone utilizar índices que relacionan los distintos tipos de pérdidas de potencia del motor con el fin de utilizarlos para determinar el fallo² o la alteración en la condición de operación del motor, es decir, un fallo en la máquina repercute en su eficiencia y por lo tanto en los índices propuestos. Este trabajo se organiza de la siguiente forma: la sección II hace una descripción de las pérdidas del motor y los índices propuestos. En la sección III se muestra el banco de pruebas y las pruebas realizadas al motor, la sección IV muestra los experimentos realizados utilizando los cinco índices para la construcción de un prototipo de sistema de diagnóstico basado en redes neuronales artificiales, además se realiza un análisis de la variabilidad de los índices bajo condiciones tanto normales como anormales del motor, tomando en cuenta la sensibilidad y similitud entre los índices propuestos para identificar y categorizar faltas en el motor. La sección V presenta un análisis de resultados general y, finalmente, la sección VI las conclusiones.

2. Pérdidas del motor de inducción y definición de índices

Las potencias por pérdidas son resultado de un deficiente proceso de conversión de energía eléctrica a mecánica. Así, la potencia total de pérdida se calcula como la diferencia entre la potencia de entrada P_{in} y la de salida P_{out} , tal y como se muestra en la ecuación (2)

$$P_{loss} = P_{in} - P_{out} = P_s + P_r + P_{mis} \quad (2)$$

donde P_s representa la pérdida del estator, P_r la del rotor y P_{mis} las potencias mecánica y misceláneas. Además, la potencia por pérdidas del estator P_s se calcula por medio de la ecuación (3), donde P_{cs} es la potencia de pérdida por efecto Joule en los devanados estatóricos y P_{ns} la potencia por pérdidas en el núcleo debido a corrientes parásitas e histéresis.

$$P_s = P_{cs} + P_{ns} \quad (3)$$

$$P_{cs} = R_s(I_a^2 + I_b^2 + I_c^2)(1 + 0.00389(\Delta\theta)) \quad (4)$$

² Entiéndase falta y fallo como equivalentes, en el contexto de este trabajo.

La potencia P_{cs} se calcula como en la ecuación (4), donde R_s es la resistencia estatórico medida a la temperatura ambiente, los términos I_a, I_b, I_c son las corrientes por fase, el término $\Delta\theta$ representa la diferencia de temperatura del devanado estatórico y la temperatura ambiente.

Por otro lado, las potencias por pérdidas del rotor P_r se determinan según la ecuación (5), donde s es un número adimensional que se calcula según la ecuación (6), n_{scr} es la velocidad sincrónica y n_{mec} es la velocidad mecánica del motor

$$P_r = (P_{in} - P_{cs} - P_{ns}) s \quad (5)$$

$$s = \frac{n_{scr} - n_{mec}}{n_{scr}} \quad (6)$$

Luego, la pérdida P_{mis} se puede estimar como en la ecuación (7)

$$P_{mis} = \chi(P_{in} - P_{out}) \quad (7)$$

donde χ oscila entre $[0, 0.11]$ según datos de [5], se puede calcular de forma experimental por medio de las pérdidas mecánicas y misceláneas.

Dado que las ecuaciones (3) y (5) dependen de P_{ns} , es necesario estimarla. Para ello, se sustituye (3), (5) y (7) en (2) para obtener la potencia del núcleo P_{ns} en términos de parámetros medidos

$$P_{ns} = \frac{(1 - s - \chi)P_{in} - (1 - s)P_{cs} - (1 - \chi)P_{out}}{(1 - s)} \quad (8)$$

Nuevamente, al sustituir (8) en (3) y (5) se obtienen expresiones que solamente dependen de las mediciones realizadas. De esta forma las expresiones para P_s y P_r , tomando $\chi = 0$, son aproximadas por las expresiones en (9) y (10).

$$P_s \approx P_{in} - \frac{P_{out}}{(1 - s)} \quad (9)$$

$$P_r \approx s \frac{P_{out}}{(1 - s)} \quad (10)$$

2.1. Definición de índices

En esta sección se definen cinco índices calculados por medio de las pérdidas del motor expuestas anteriormente. En conjunto, estos índices logran determinar si hay cambios en la carga del motor, alteraciones en el voltaje de alimentación o un calentamiento por pobre ventilación.

Los índices que se proponen son

$$\begin{aligned} I_{cs} &= \frac{P_{cs}}{P_{loss}}, & I_{ns} &= \frac{P_{ns}}{P_{loss}}, & I_r &= \frac{P_r}{P_{loss}} \\ I_{rcs} &= \frac{P_r}{P_{cs}}, & I_{rs} &= \frac{P_r}{P_s} \end{aligned} \quad (11)$$

El índice I_{cs} establece una relación entre las pérdidas que ocurren por efecto Joule entre el devanado estatórico y las pérdidas totales, este índice varía de acuerdo a los cambios en el voltaje de alimentación. A su vez I_{ns} calcula la relación entre la potencia disipada en el núcleo de la máquina y la total desperdiciada. El índice I_r relaciona las pérdidas del rotor entre el total de pérdidas. Los índices I_{rcs} y I_{rs} buscan establecer las relaciones específicas entre dos tipos de pérdidas de potencia, el primer caso establece la relación entre potencias perdidas en el rotor y cobre del estator y el segundo índice relaciona las pérdidas del rotor y el estator.

3. Banco de pruebas

El banco de pruebas para motores trifásicos que se construyó se compone de un generador de corriente directa de 5 kW y un banco de resistencias de 7 kW. El banco posee tres auto transformadores monofásicos conectados en estrella para provocar bajos y altos voltajes de alimentación así como desbalances. En la figura 1a se muestra una fotografía parcial del banco de pruebas implementado.

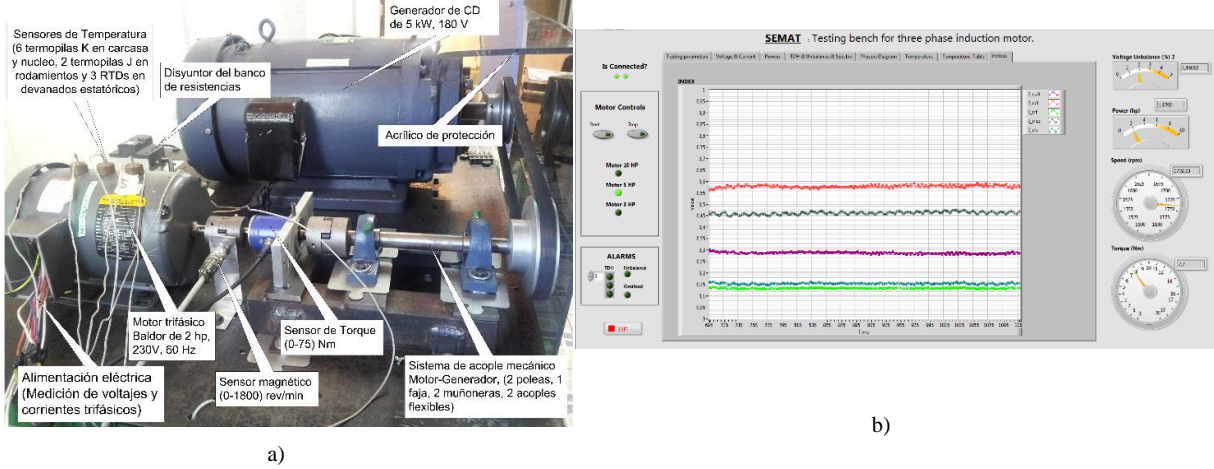


Figura 1: a) Banco de pruebas implementado. Tomado de [6] b) Interfaz gráfica con los índices calculados en tiempo real

Para interconectar el banco de pruebas con el sistema de adquisición de datos, se desarrolló una aplicación informática [6] que gestiona el banco de pruebas y somete los motores a experimentos controlados en donde se definen los parámetros de la prueba. La aplicación controla los estímulos del motor (carga del motor, tiempos de encendido o apagado), monitorea su reacción y se registra todas las variables de interés.

El programa implementa, en tiempo real, el cálculo de los cinco índices propuestos tal como se muestra en la figura 1b. Cada segundo se publica la media móvil de los últimos diez valores con la finalidad de suavizar las curvas. Cuando la prueba finaliza, la aplicación guarda, en archivo de texto, todas las variables eléctricas, mecánicas y los índices propuestos. Así, el archivo contiene los índices calculados en cada segundo durante la prueba.

3.1 Pruebas realizadas

El motor en estudio es de la marca Baldor modelo M3558 de 2hp, 230 V, 60 Hz. Los fallos a los que se somete el motor se realizaron durante su transitorio térmico. Un buen modelo que aproxima este comportamiento lo plantea [7], indicando que la respuesta térmica del motor se modela como un sistema de primer orden cuyo resultado se presenta en la ecuación (12).

$$\theta = P_{loss} \cdot R_{th} \cdot \left(1 - e^{\frac{-t}{R_{th}C_{th}}}\right) + \theta_A \quad (12)$$

Donde θ y θ_A son las temperaturas interna y la ambiental respectivamente, el término P_{loss} representa la totalidad de pérdidas del motor como se mostró en la sección 2, el término R_{th} representa una resistencia térmica equivalente del motor, C_{th} representa la capacitancia térmica equivalente del motor y el término t representa el tiempo.

El estado estable de la máquina sin fallos asociados se alcanza en 5τ , donde $\tau = R_{th}C_{th}$. Sin embargo, para efectos experimentales se considera que se alcanza el equilibrio térmico cuando dos cambios consecutivos de la temperatura interna, separados por un lapso de cinco minutos, no varía en menos de un grado centígrado, esto es

$$|\theta_t - \theta_{t-5min}| \leq 1^\circ C \quad (13)$$

Para el motor en cuestión, el transitorio térmico experimental se alcanzó aproximadamente en los 8000 segundos bajo el criterio anterior. Durante todo el transitorio térmico se somete el motor a una condición anormal, ya sea subvoltaje, desbalance o un cobertor que simula poca ventilación, dichas condiciones se denominan fallos tipo uno, dos o tres, respectivamente, la tabla 1 muestra la descripción de los mismos.

De forma similar al 100% de carga, se realizaron pruebas al 75% y al 50% de carga, en el código de la prueba se sustituye el término C100 por C75 y C50, según corresponda.




Figura 2: Comportamiento térmico de experimentos realizados al motor con 100% de carga

La figura 2 muestra el comportamiento de la temperatura del motor ante los tres tipos de fallos indicados anteriormente y la curva de funcionamiento normal, al 100% de carga. En dicha figura se puede observar que la diferencia entre el comportamiento de cada fallo y el comportamiento normal es mínima, por lo que detectar alguno de esos fallos en el motor no es una tarea sencilla.

Tabla 1: Resumen de condiciones de fallo al 100% de carga

Fallo	Carga	Voltaje (V)	Desbalance.	Cobertor.	Código
Sin fallo	100%	230	<1%	No	C100
Tipo 1	100%	200	<1%	No	C100V115 ³
Tipo 2	100%	230	3%	No	C100D3
Tipo 3	100%	230	<1%	Si	C100Cobertor

³ 200V \approx 1.73 · 115V

4. Experimentos realizados y valoración de índices

Esta sección muestra los experimentos realizados y sus resultados con el fin de determinar la viabilidad de los índices para el diagnóstico de fallos. Primeramente, se utilizó una red neuronal artificial como prototipo de un sistema de diagnóstico automático. Posteriormente, se utilizan mapas autoorganizados para analizar si los índices poseen redundancia. Finalmente, se realiza un análisis gráfico de los índices para distintas pruebas en donde se confirma que existe duplicidad en la información que aportan algunos indicadores.

4.1 Redes neuronales

Una red neuronal artificial es un modelo simplificado del sistema neuronal humano [8],[9]. La unidad más simple de una red neuronal es la neurona artificial, la cual posee dos etapas, la primera suma los productos de la entrada $I(j)$ por el factor de su peso de arco $W(j)$, luego se le suma un factor de polarización llamado bias b . La segunda etapa consiste en utilizar el resultado de la suma anterior y realizar la activación de la neurona mediante una función de transferencia. Existen varios tipos de funciones de activación [10], entre ellas *Sigmoid* (a) *Logsig*(a), *Purelin*(a), para este trabajo se utiliza la llamada *Tansig*(a). La figura 3a muestra una representación gráfica del modelo descrito anteriormente y la ecuación (14) su representación algebraica.

$$a = \sum_{j=1}^n [W(j)I(j)] + b \quad (14)$$
$$y = \text{Tansig}(a) = \frac{2}{1 + e^{-2a}} - 1$$

4.1.1 Clasificador basado en red neuronal

Se diseñó una red neuronal artificial (RNA) tipo “feedforward” para decidir si un motor eléctrico presenta alguno de los tres tipos de fallos descritos en la tabla 1 o si se encuentra en funcionamiento normal. La red posee diez entradas distribuidas de la siguiente forma: cinco entradas una para cada índices calculado en un instante específico y las otras cinco entradas para los valores anteriores a las muestras actuales. La red posee una capa oculta de diez neuronas y una capa de salida con cuatro neuronas, una por cada fallo más la salida para el funcionamiento normal. Cada una de las neuronas son idénticas y poseen el funcionamiento de la ecuación (14). Las neuronas de la capa oculta se definieron con la siguiente regla heurística

$$\text{Neuronas} \geq \frac{N_e + N_s}{2} \quad (15)$$

donde N_e y N_s representa cantidad de entradas y salidas respectivamente. Se definieron diez neuronas ocultas con el fin de incrementar la exactitud y disminuir el error cuadrático medio.

La figura 3b muestra la descripción anterior, los rombos representan los puertos de entrada y el término Z^{-1} indica que esa entrada específica ingresa la muestra anterior del *dataset*, W_1 representa la matriz de pesos de la capa oculta, esta matriz posee dimensión 10×10 y la matriz de pesos de las neuronas de salida se representa como W_2 y posee una dimensión de 4×10 . La salida vectorial F de la red neuronal queda descrita por la ecuación (16).

$$F = \text{Tansig}(W_2 \cdot \text{Tansig}(W_1 \cdot I + b_1) + b_2) \quad (16)$$

donde \mathbf{I} es el vector de entradas, \mathbf{b}_1 es el vector de bias de las neuronas de la capa oculta de tamaño 10×1 y \mathbf{b}_2 es el bias de las neuronas de la capa de salida que posee un tamaño 4×1 .

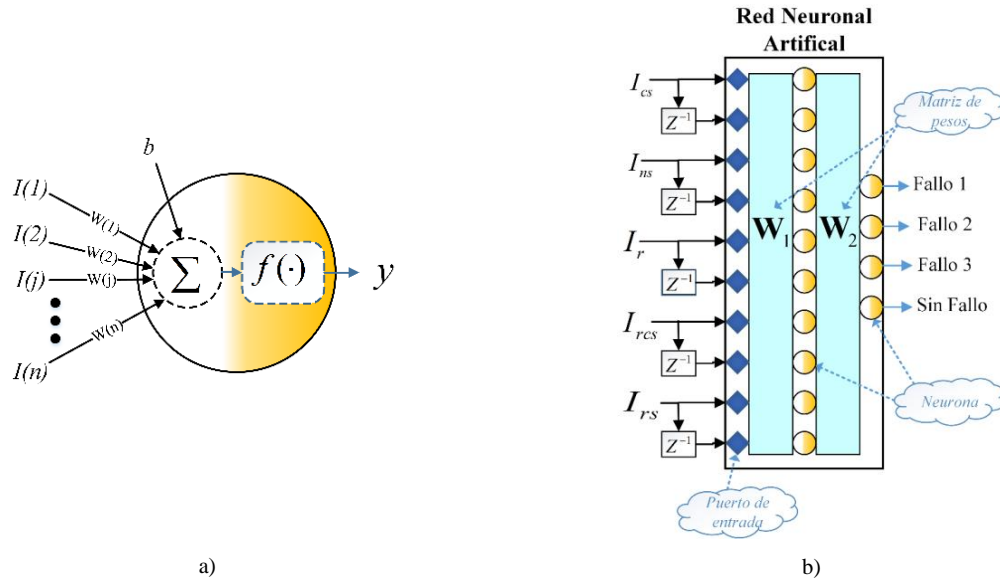


Figura 3: a) Neurona artificial b) RNA para clasificación de fallos de un motor eléctrico

4.1.2 Entrenamiento de red

A fin de ajustar los pesos almacenados en las matrices \mathbf{W}_1 , \mathbf{W}_2 y en los vectores \mathbf{b}_1 y \mathbf{b}_2 se realizaron varios entrenamientos supervisados de la red. El mejor resultado se logró con el algoritmo Levenberg–Marquardt con aprendizaje basado en gradiente descendente y momento. La tasa de aprendizaje usada fue de 0.01 y la constante del momento usada fue de 0.9.

Tal y como se mencionó, el motor en estudio se expuso a los fallos descritos en la tabla 1 y se almacenaron en cada segundo, los cinco índices definidos en la sección 2.1. El fallo a que se somete el motor está presente durante el transitorio térmico.

Para construir el conjunto de datos de prueba (*dataset*) se unificaron las tres pruebas y la prueba en funcionamiento sin fallo, dicho *dataset* posee más de 36000 registros. Posteriormente, se muestreó de forma uniforme cada 180 muestras y se construyó el *dataset* definitivo que posee 200 registros, cada 50 registros corresponde a una prueba específica. Es importante señalar que los 50 registros calculan los índices en distintos instantes del transitorio térmico del motor.




Figura 4: Error cuadrático medio vs entrenamiento y validación

Con la arquitectura de la red neuronal y el *dataset* definitivo se procedió, primeramente, a realizar el entrenamiento supervisado con el algoritmo de retropropagación. La retropropagación es una técnica en la que la red es entrenada con un conjunto de entradas y salidas conocidas y para cada iteración del algoritmo, los pesos de las matrices \mathbf{W} y \mathbf{b} son auto ajustados, con el fin de minimizar el error entre la salida actual y su valor esperado. Este ajuste se aplica desde las capas de salida hasta las capas de entrada, de ahí el nombre de retropropagación. Para el presente trabajo este algoritmo no brindó los resultados esperados dado que el error cuadrático medio presentó valores alrededor de 0.22, considerado alto por los autores. Por esta razón se optó por utilizar el algoritmo Levenberg–Marquardt que se utiliza para minimizar funciones por mínimos cuadrados no lineales [9].

La figura 4 muestra la gráfica de error cuadrático medio (mse) versus la cantidad de entrenamientos completos con el *dataset* definitivo. Se observa un mse de 0.03197 en veintiocho *epochs*.

Una vez entrenada la red, se construyó un segundo *dataset* con la finalidad de probarla. Se definió un valor umbral de aceptación de fallos mayor a 0.85. Así, cuando la RNA arroja, en una salida, un valor superior al umbral se considera que la red ha detectado una condición particular, ya sea funcionamiento normal o fallo tipo uno, dos o tres.

Un valor muy alto del umbral hace que el sistema de clasificación genere muchos falsos negativos, es decir, que no detecte cuando hay fallos específicos. Por otro lado, con bajos valores del umbral se corre el riesgo de generar falsos positivos, es decir que el sistema indique que hay un fallo específico cuando en realidad no existe.




Figura 5: Clasificación por índices

La figura 5 muestra los resultados de la RNA con el segundo *dataset* construido. Al igual que el primero, este *dataset* posee 200 registros, y cada 50 muestras corresponde a un tipo de fallo, las primeras 50 muestras pertenecen al fallo tipo uno, los siguientes 50 registros al fallo tipo dos y así sucesivamente. Se señala nuevamente que las 50 muestras para cada prueba realizada poseen un espaciamiento temporal uniforme de

180 segundos. Esto a su vez implica que los cinco índices fueron calculados durante el régimen transitorio de temperatura.

Además, se observa en la figura 5 que, con los índices propuestos, la RNA detecta los fallos tipo 1 en cualquier instante del transitorio térmico en que ocurra. Esto concuerda con la primera gráfica de correlación de la figura 6, que muestra la correlación del resultado de la red versus el valor real. Para este caso el valor de correlación es de $R = 0.98889$.

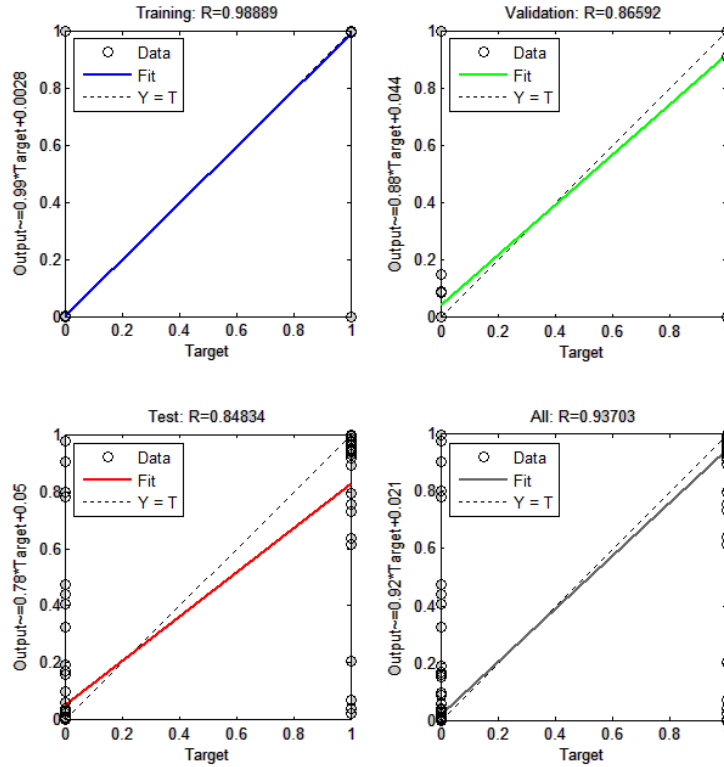


Figura 6: Correlaciones de los resultados de la RNA vs el valor real

Para la prueba del motor con el fallo inducido tipo dos, este presenta tanto falsos negativos como falsos positivos. Este se ve reflejado en el índice de correlación de resultados versus valores reales que es de $R = 0.8483$. Para las pruebas tipo tres, la RNA no diagnóstica algunos casos de este fallo cuando el motor lo sufre (falso negativo), su índice de correlación es de 0.86592. Finalmente, cuando la red no presenta fallo la RNA logra determinar la gran mayoría de los casos, el índice de correlación es de 0.93703.

4.2 Mapas autoorganizados

Un mapa autoorganizado (SOM) es un tipo de red neuronal artificial, que se entrena utilizando un aprendizaje no supervisado para producir una representación discreta del espacio de las muestras de entrada [8], [9]. Organizándolas o agrupándolas de acuerdo a patrones o características comunes, tomando en cuenta tanto la competitividad, como la cooperatividad entre dichas muestras. En la etapa de competitividad, para cada muestra $I(j)$ se selecciona la neurona con la distancia euclídea más pequeña, según la ecuación (21), donde cada neurona representa una región en el espacio de entrada.

$$i^* = \operatorname{argmin}_i \|w_i - I(j)\| \quad (17)$$

La neurona con vector de pesos más similar a la entrada es la ganadora. Por otro lado, en la etapa de cooperatividad, cada neurona se compara con sus neuronas vecinas, en la cual tanto el vector de pesos de la neurona ganadora es actualizado, por medio de una regla de actualización Δw_i , como el mallado de su vecindario. Para ello se utiliza una función Gaussiana de vecindad Λ , centrada en la neurona ganadora y decreciente respecto a la distancia de la neurona ganadora.

$$\Delta w_i = \alpha \Lambda(i, i^*, \sigma_\Lambda(t))(I(j) - w_i) \quad (18)$$

$$\Lambda(i, i^*) = \exp\left(-\frac{\|r_i - r_{i^*}\|^2}{2\sigma_\Lambda^2}\right)$$

donde r_i y r_{i^*} representan los nodos del mallado discreto con una topología regular [11].

4.2.1 Similitud de índices con pruebas al 100% de carga por medio de SOM

Con la finalidad de analizar y detectar similitudes entre el comportamiento de los cinco índices definidos en la sección 2.1, se entrenó un SOM de 4×4 neuronas, con una tasa de aprendizaje $\alpha = 0.02$ y desviación estándar $\sigma_\Lambda = 0.45$, tomando como entradas los valores de los cinco índices en las pruebas definidas en la tabla 1.

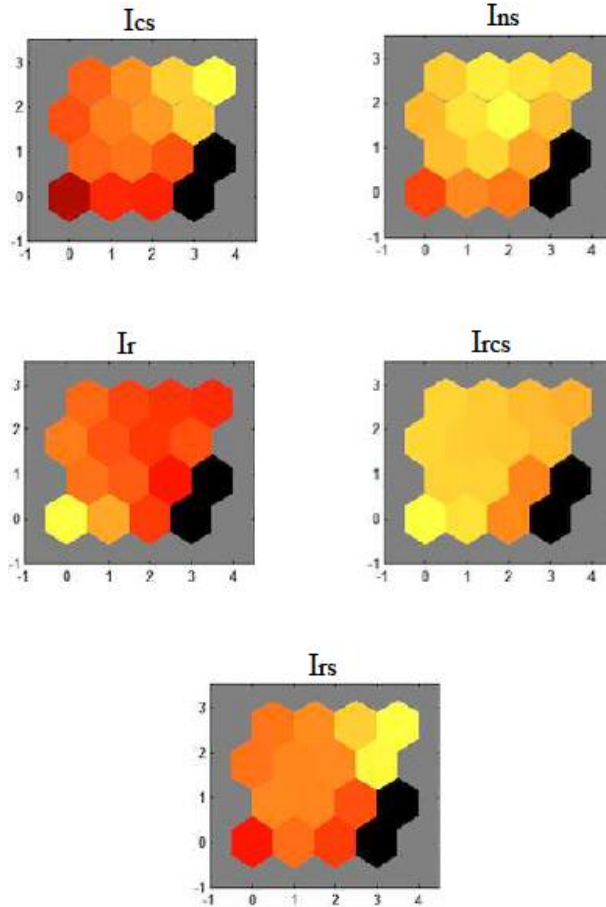


Figura 7: SOM de 4×4

La figura 7 muestra los resultados del entrenamiento del mapa autoorganizado con una malla de 4×4 , donde las neuronas en negro indican que no hay valores asociados a las mismas. Además, la escala de colores amarillo-rojo indica que entre más intenso u oscuro es el tono hay más valores asociados a la neurona, el amarillo representa menor intensidad y el rojo mayor intensidad. Así, según el patrón obtenido con el SOM, los cinco índices propuestos se pueden organizar en tres grupos

$$\begin{array}{ccc} \bullet & I_{cs} & \bullet & I_{ns} & \bullet & I_r \\ & I_{rs} & & I_{rcs} & & \end{array}$$

suponiendo que mapas similares indican características y comportamiento similares de los índices. Por lo que se podría reducir la cantidad de índices a solamente tres, uno por grupo

$$\bullet \quad I_{rs} \quad \bullet \quad I_{rcs} \quad \bullet \quad I_r$$

Tomando los tres anteriores como representativos o significativos, y además suficientes, para entrenar la RNA de la sección 4.1. y así intentar describir el comportamiento con fallo del motor.

4.3 Variabilidad de índices

Siguiendo los resultados obtenidos por medio del SOM para el caso de pruebas al 100% de carga, se realizó un análisis de los índices por tipo de fallo, de manera independiente, y además se generalizó para pruebas al 75% y al 50% de carga. Con el objetivo de validar la agrupación y selección de índices realizada en la sección 4.2.1. y además analizar la variación de los mismos por tipo de prueba (100%, 75% y 50% de carga) y por tipo de fallo (condiciones normales del motor, subvoltaje, desbalance y cobertor).

En las figuras 8 se muestra la distribución de los valores de cada índice bajo condiciones nominales del motor y para cada uno de los tres fallos con los que se entrenó la RNA de la sección 4.1. (subvoltaje con 200V, 3% de desbalance y cobertor) y además se analizó un caso más de desbalance al 4%.

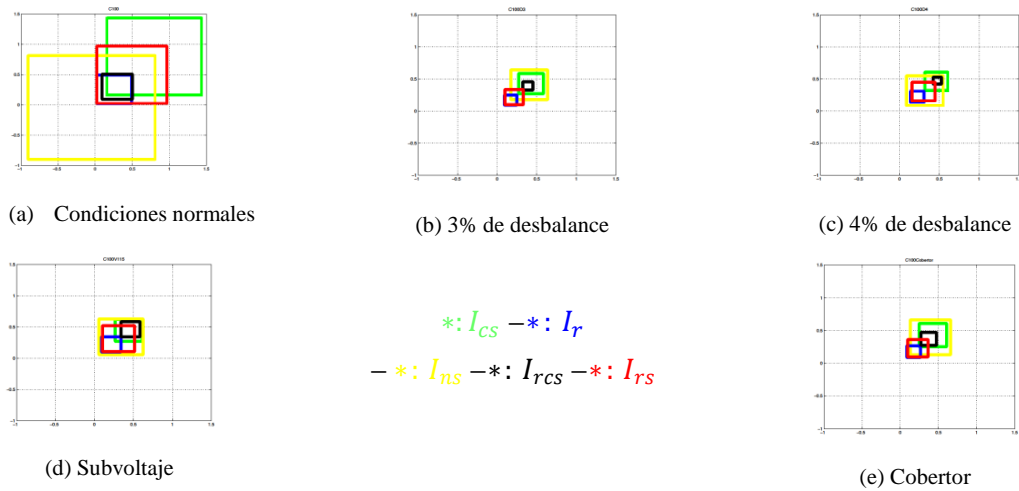


Figura 8: Índices al 100% de carga

Tomando como referencia el valor de los índices en el tiempo y en cada una de las pruebas de manera independiente, cada color representa un índice y cada uno de los recuadros está centrado en la media de los valores de cada índice, según corresponda. Por lo que se puede observar la variación de cada índice respecto a su media y respecto a la variación de los demás índices en cada una de las pruebas.

La figura 8 muestra como los recuadros en azul, negro y rojo mantienen un patrón similar, en rango, en cada una de las pruebas, en contraposición a los recuadros verde y amarillo que presentan una variación más marcada en sus posiciones de una prueba a otra. Por otro lado, se puede observar como el par de recuadros amarillo-negro se complementan en dimensión y el amarillo siempre contiene al negro. Asimismo el par verde-rojo siempre se traspone de la misma manera, con una intersección significativa entre ellos.




Figura 9: a) Índices al 100% de carga b) Índices representativos al 100% de carga

: I_{CS} —: I_r —*: I_{nS} —*: I_{rcs} —*: I_{rs}

Además, la figura 9a muestra los índices al 100% de carga por medio de una representación lineal, donde el centro de cada franja de color está dado por la media de cada índice en el tiempo, según corresponda. Con lo que es posible reafirmar lo observado en la figura 8.

Los resultados anteriores coinciden con los obtenidos por medio del SOM en la figura 7, dado que en el mapa autoorganizado se toman en cuenta los índices de manera conjunta, en condiciones nominales y con los tres tipos de fallos (subvoltaje, desbalance y cobertor) para realizar su representación gráfica. Ubicando a I_{CS} y a I_{rs} bajo un mismo patrón de comportamiento, lo mismo para I_{nS} y I_{rcs} , y categorizando los índices en tres grupos.

Así, tomando como referencia un índice por grupo, I_r , I_{rcs} y I_{rs} son suficientes para entrenar la RNA de la sección 4.1., utilizándola para caracterizar el comportamiento del motor y ubicarlo en alguno de los cinco estados analizados: condición nominal del motor, subvoltaje con 200V, 3% de desbalance, 4% de desbalance y cobertor, tal y como se muestra en la figura 9b.

Generalizando los resultados anteriores para los casos al 75% y al 50% de carga, se toman en cuenta las pruebas en condiciones nominales del motor, con fallo tipo 1 (subvoltaje con 200V) y fallo tipo 3 (cobertor) al 75% de carga, ver figuras 10-11.




Figure 10: Índices al 75% de carga , *: I_{CS} —*: I_r —*: I_{nS} —*: I_{rcs} —*: I_{rs}

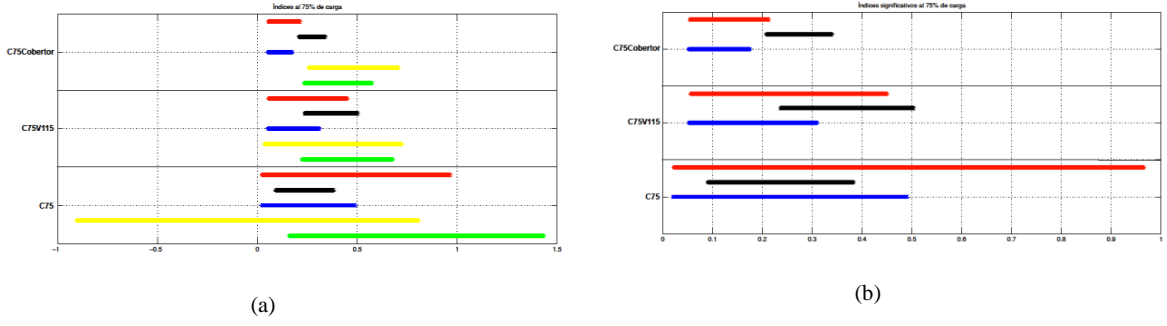


Figura 11: a) Índices al 75% de carga b) Índices representativos al 75% de carga

: I_{CS} —: I_r —*: I_{nS} —*: I_{rcs} —*: I_{rs}

Para el caso de 50% de carga, se toman en cuenta las pruebas en condiciones nominales del motor, con fallo tipo 1 (subvoltaje con 200V) y con fallo tipo 2 (3% de desbalance), ver figuras 12-13.




Figure 12: Índices al 50% de carga , *: I_{CS} —*: I_r —*: I_{nS} —*: I_{rcs} —*: I_{rs}

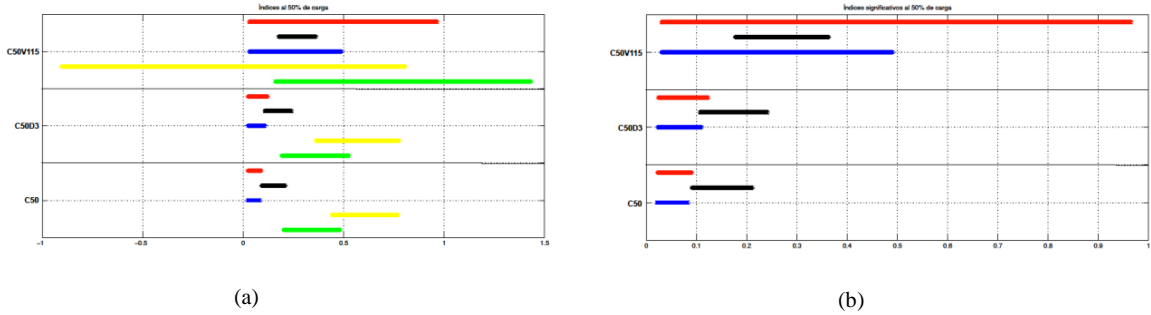


Figura 13: a) Índices al 50% de carga b) Índices representativos al 50% de carga

: I_{CS} —: I_r —*: I_{nS} —*: I_{rcs} —*: I_{rs}

Similarmente al caso con 100% de carga, en las figuras 10-11a y 12-13a se puede observar como la complementariedad del par de índices $I_{nS} - I_{rcs}$ (amarillo-negro) y el patrón de comportamiento del par $I_{CS} - I_r$ (verde-azul) se mantiene para los casos al 75% y al 50% de carga, según corresponda. Así, en las figuras 11b y 13b se muestra la representación gráfica lineal de los índices que se toman como representativos para entrenar la RNA de la sección 4.1. y así intentar caracterizar y categorizar el funcionamiento del motor, ahora al 75% y al 50% de carga.

5. Análisis de resultados

Los resultados de la RNA muestran que los índices propuestos logran discriminar los fallos inducidos al motor durante su transitorio térmico con 100% de carga. Es decir estos índices son capaces de operar en

régimen transitorio como en régimen estable, lo que permite ser utilizados e implementados en el diagnóstico en tiempo real de los motores eléctricos.

Además, los resultados que arroja la RNA pueden ser fácilmente mejorados si se realizan acciones como

- Aumentar al tamaño del **dataset** con pruebas similares en otro momento.
- Aumentar la cantidad de las capas ocultas de la RNA y/o neuronas en cada capa.
- Incrementar las entradas de la RNA retardadas, es decir, agregar entradas con doble retardo Z^{-2} para cada índice
- Explorar con otros algoritmos entrenamiento adaptativos / evolutivos.
- Realizar estudios más detallados variando los parámetros de inicio de los algoritmos.
- Explorar otras topologías de redes neuronales tales como RNA dinámicas, etc.

Por otro lado, el análisis en la similitud y variación de los índices realizado por medio de SOM indica que es suficiente con tomar solamente tres índices, dado que es posible agruparlos en tres grupos de acuerdo a sus patrones de comportamiento en el tiempo, bajo tres porcentajes de carga (100, 75 y 50) y ante distintos tipos de fallo (subvoltaje, desbalance y cobertor). Así, se toman I_r - I_{rcs} - I_{rs} como índices representativos o significativos para entrenar la RNA, categorizar el comportamiento del motor en el tiempo y así detectar algunos de los fallos definidos en la tabla 1.




Figura 14: Índices representativos, *: I_r -*: I_{rcs} -: I_{rs}

En la figura 14 se muestra el resumen de los índices representativos, en todos los casos presentados en la sección 4.3., donde se puede notar que dichos índices pueden ser capaces de discriminar no solo por tipo de fallo sino que también por porcentaje de carga.

6. Conclusiones

En este trabajo se valoraron cinco índices basados en las distintas pérdidas de motor con la intención de diagnosticar fallos específicos en la máquina. Se realizó un análisis teórico de sensibilidad para observar si los índices son capaces de diagnosticar nueve tipos de fallos distintos. Se requiere realizar más análisis al respecto pero se vislumbra que los índices en conjunto pueden mapear distintos fallos que afectan la máquina.

La viabilidad de utilizar los índices, para constituir un sistema que diagnostique fallos en tiempo real, se ha demostrado utilizando una red neuronal artificial entrenada con los índices calculados en distintos instantes

del régimen transitorio. Esto permite que cuando un fallo particular aparezca, ya sea en régimen transitorio o estable, el sistema con pocas muestras sea capaz de determinar el tipo de fallo que afecta al motor.

Agradecimientos

Se agradece a la Vicerrectoría de Investigación y Extensión del Tecnológico de Costa Rica por el apoyo brindado al proyecto VIE 5402-1341-1301. Se agradece al Ing- Osvaldo Guerrero-Castro y a sus asistentes por las pruebas realizadas al motor trifásico con el fin de generar datos para el análisis.

Referencias

- [1] A. Boglietti, A. Cavagnino, M. Lazzari, and M. Pastorelli, "A Simplified Thermal Model for Variable-Speed Self-Cooled Industrial Induction Motor," *IEEE Transactions on Industry Applications*, vol. 39, no. 4, pp. 945–952, 2003.
- [2] M. Duran and J. Fernandez, "Lumped Parameter Thermal Model for Induction Machines," 2004.
- [3] G. Figueroa-Mata and L. D. Murillo-Soto, "Algoritmo bioinspirado aplicado a la estimación de los parámetros de un modelo térmico para un motor trifásico de inducción," in *12° Congresso iberoamericano de engenharia mecanica (CIBIM XII)*, (Guayaquil), 2015.
- [4] L. D. Murillo-Soto, G. Figueroa-Mata, and O. Guerrero-Castro, "Identificación de parámetros de un modelo térmico para un motor trifásico de inducción usando algoritmos gen éticos," *Revista Tecnología en Marcha*, vol. 29, no. 5, pp. 25–41, 2016.
- [5] W. Cao, "Comparison of iec 60034-2-1 and new iec standard 60034-2-1," *Energy Conversion, IEEE Transactions on*, vol. 24, no. 3, pp. 802–808, 2009.
- [6] L. D. Murillo-Soto, "Aplicación informática para el monitoreo de variables eléctricas, mecánicas y térmicas en motores trifásicos de inducción," in *Latin American and Caribbean Conference for Engineering and Technology (LACCEI'2014)*, (Guayaquil), 2014.
- [7] S. E. Zocholl, "Comparing motor thermal models," in *In 31st Annual Western Protective Relay Conference*, (WA), pp. 1–10, Schiweitzer Engineering Laboratories, Inc., 2004.
- [8] R. Lippmann, "An introduction to computing with neural nets," *IEEE Assp magazine*, vol. 4, no. 2, pp. 4–22, 1987.
- [9] S. S. Haykin, S. S. Haykin, S. S. Haykin, and S. S. Haykin, *Neural networks and learning machines*, vol. 3. Pearson Upper Saddle River, NJ, USA:, 2009.
- [10] M. Dorofki, A. H. Elshafie, O. Jaafar, O. A. Karim, and S. Mastura, "Comparison of artificial neural network transfer functions abilities to simulate extreme runoff data," *International Proceedings of Chemical, Biological and Environmental Engineering*, vol. 33, pp. 39–44, 2012.
- [11] M. M. Van Hulle, *Self-organizing Maps*, pp. 585–622. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012.

Predicción de la temperatura del rotor de un motor eléctrico, mediante algoritmos bioinspirados

Geovanni Figueroa-Mata
School of Mathematics
Instituto Tecnológico de Costa Rica
Cartago, Costa Rica 159-7050
Email: gfigueroa@itcr.ac.cr

Cindy Calderón-Arce
School of Mathematics
Instituto Tecnológico de Costa Rica
Cartago, Costa Rica 159-7050
Email: ccalderon@itcr.ac.cr

Abstract—Se plantea un modelo térmico simplificado para un motor trifásico Baldor modelo M3558, de 2 hp, 230V, 60 Hz. Para dicho modelo se obtienen las ecuaciones diferenciales asociadas y se hace la estimación de sus parámetros térmicos (capacitancias y conductancias) mediante algoritmos bioinspirados. Para estimar los parámetros se alimenta cada algoritmo bioinspirado con las pérdidas y las temperaturas del motor eléctrico capturadas por un banco de pruebas construido para tal fin. El algoritmo bioinspirado va ajustando cada parámetro hasta que se cumplan los criterios de ajuste establecidos, para ello se utilizan dos algoritmos Artificial Bee Colony y Differential Evolution. En la parte final del trabajo se comparan los parámetros térmicos obtenidos por ambos algoritmos contra el ajuste de las temperaturas del rotor y estator obtenidas a partir del modelo generado con las ecuaciones diferenciales y los parámetros encontrados. Se muestra que los parámetros obtenidos mediante los algoritmos bioinspirados presentan un buen ajuste respecto a los datos y no requieren del conocimiento de las magnitudes y constantes físicas relacionadas con el motor.

I. INTRODUCTION

Los motores eléctricos de inducción representan la principal fuerza motriz para accionar los sistemas electromecánicos, estimar de forma correcta la temperatura interna de la máquina es una necesidad por las implicaciones que esto tiene sobre la vida útil de la máquina. Los materiales y barnices aislantes del motor se degradan de forma exponencial, por cada 10°C por encima de la temperatura máxima de la clase del aislamiento la vida útil se reduce a la mitad [1], [2].

Para el control y predicción de la temperatura interna de un motor, se han propuesto algunos modelos, de acuerdo con [3] los modelos de primer orden son rápidos y eficientes, presentan una buena estimación de la temperatura y necesitan solamente el valor de la corriente estatórica, pero esta estimación es un promedio general que no permite determinar los puntos calientes de la máquina. En [4] se realiza una comparación entre distintos tipos de modelos de primer orden, los cuales poseen una estructura similar a la ecuación (1)

$$\theta = I^2 R R_{th} \left(1 - \exp \left(\frac{-t}{R_{th} C_{th}} \right) \right) + \theta_A \quad (1)$$

donde θ y θ_A son las temperaturas interna y ambiental, respectivamente, el término $I^2 R$ representa las pérdidas totales del motor, R_{th} representa una resistencia térmica equivalente y C_{th} representa la capacitancia térmica del motor.

Por otro lado, los modelos térmicos mallados para estados estables permiten predecir la temperatura en zonas específicas de la máquina, con el inconveniente de que la estimación de temperaturas en el transitorio térmico presenta errores de hasta un cien por ciento. Estos modelos en estado estable, tales como los que se plantean en [5]–[7], obtienen las temperaturas resolviendo el sistemas de ecuaciones lineales dado en (2), donde P es el vector de pérdidas de la máquina, G es la matriz de conductancias térmicas del motor y θ es el vector de temperaturas a calcular.

$$P = G\theta \quad (2)$$

Los modelos térmicos mallados para estados transitorios son aquellos que pueden predecir la temperatura en un punto específico de la máquina, tanto en régimen transitorio como en estado estable. Estos modelos incorporan un tercer vector a la ecuación (2), el cual se forma al multiplicar una matriz C que contiene en su diagonal las capacitancias térmicas de la máquina, por un vector que contiene las derivadas de las temperaturas respecto al tiempo $\frac{d\theta}{dt}$, de tal forma que la expresión general está dada por

$$C \frac{\partial \theta}{\partial t} = P - G\theta \quad (3)$$

Otros modelos más complejos, como los que se plantean en [1], [8], [9], representan el estado transitorio. Estos ofrecen una predicción de la temperatura en el respectivo nodo, pero para poderla estimar se requiere conocer los materiales, geometrías, dimensiones y masas para calcular cada conductancia térmica entre los nodos y la matriz de capacitancia. Adicionalmente se requiere conocer en forma detallada cada una de las pérdidas reales de la máquina, para esto es necesario realizar pruebas de laboratorio. Cabe señalar que estos inconvenientes también se presentan en los modelos en estado estable, ecuación (2).

Por otro lado la estimación de temperatura con base en parámetros eléctricos, se divide fundamentalmente en dos esquemas. El primer esquema surge del estándar IEEE 112 [10], donde se indica que la variación de la temperatura interna provoca variaciones de las resistencias estatóricas y rotóricas del motor en la siguientes proporciones

$$\theta_2 = \frac{R_2}{R_1}(\theta_1 + k) - k \quad (4)$$

R_1 representa la resistencia a la temperatura θ_1 , usualmente medida a temperatura ambiente con motor apagado, R_2 la resistencia a la temperatura θ_2 y k es el coeficiente del material conductor, donde para el cobre es 234.5 y para el aluminio es de 225. Para obtener el valor de las resistencias se utilizan dos métodos, el primero calcula la resistencia aplicando la ley de Ohm a la medición del voltaje y corriente continua (CD). El otro método es la medición directa con puente wheatstone doble, mediante un miliohmímetro. Consecuentemente y dado que el punto más caliente de una máquina es el devanado estático [11], la medición de la resistencia estática es el método más sencillo de estimación de temperaturas.

La desventaja del esquema de medición de la resistencia estática es que es invasivo, ya que requiere de equipamiento adicional y desconectar eléctricamente la máquina. Por tal motivo se han venido desarrollando métodos alternativos de obtención de la resistencia estática a partir de mediciones eléctricas de voltajes y corrientes [3], [12], [13] o frecuencias [14]. La idea de estos trabajos es desarrollar equipos en tiempo real que operen en línea con el motor y que realicen los respectivos cálculos de la estimación de temperatura interna. El principal inconveniente de estos métodos es que estiman la temperatura interna del devanado, pero no estiman el comportamiento de las temperaturas en otras zonas de interés en el motor, tal como la temperatura del núcleo, roles, carcaza, etc.

El presente trabajo propone una forma alternativa de estimar la temperatura del estator y rotor de un motor eléctrico a partir de datos experimentales y mediante la minimización de los errores vía algoritmos bioinspirados. El trabajo está organizado de la siguiente forma: en la sección II se hace una descripción del modelo térmico propuesto, en la sección III se muestran los procedimientos usados para el cálculo del vector de pérdidas del motor, en la IV el proceso utilizado para la estimación de los parámetros que alimentan el modelo descrito en la sección II, en la sección V se describen los experimentos, la construcción del banco de pruebas para la adquisición de datos y los resultados obtenidos. Finalmente, en la sección VI se presentan las conclusiones generales.

II. MODELO TÉRMICO PROPUESTO

El modelo térmico utilizado en este estudio fue propuesto en [8] y [9], ver figura 1. Este modelo se construye a partir de la ecuación general (3) y posee dos nodos llamados θ_s y θ_r que representan la temperatura promedio del estator y del rotor, respectivamente, la temperatura θ_0 se refiere a las temperaturas iniciales de θ_s y θ_r . En el modelo las pérdidas de potencia del motor se representan como fuentes de calor que elevan las temperaturas internas, la fuente del estator es llamada P_s y la del rotor P_r , los capacitores térmicos C_s y C_r representan la capacidad del estator y rotor para almacenar calor, respectivamente, son el producto de la masa del componente por el calor específico del material.




Fig. 1. Modelo térmico de un motor eléctrico de inducción. Adaptado de [8]

1) *Deducción del modelo:* A partir la ecuación (3) y del modelo térmico de la figura 1, se obtiene el siguiente sistema de ecuaciones diferenciales de primer orden

$$\begin{cases} C_s \frac{d\theta_s}{dt} = P_s - (G_s + G_{sr})\theta_s + G_{sr}\theta_r \\ C_r \frac{d\theta_r}{dt} = P_r - (G_r + G_{sr})\theta_r + G_{sr}\theta_s \end{cases} \quad (5)$$

con las condiciones iniciales $\theta_s(0) = 0$ y $\theta_r(0) = 0$, que indican que el motor se encuentra a temperatura ambiente.

Al resolver de forma analítica el sistema de ecuaciones diferenciales dado en (5) se obtienen las ecuaciones (??), que modelan la temperatura del estator θ_s y rotor θ_r en función de los parámetros térmicos y del tiempo t .

$$\begin{cases} \theta_s = C_1 \cdot \exp(r_1 t) + C_2 \cdot \exp(r_2 t) + \frac{E}{B} \\ \theta_r = C_3 \cdot \exp(r_1 t) + C_4 \cdot \exp(r_2 t) + \frac{F}{B} \end{cases} \quad (6)$$

donde r_1 y r_2 representan las soluciones de la ecuación característica asociada y además

- $C_1 = \frac{E(r_2 C_s + G_s + G_{sr}) - F G_{sr}}{B C_s (r_1 - r_2)}$
- $C_2 = \frac{E(r_1 C_s + G_s + G_{sr}) - F G_{sr}}{B C_s (r_2 - r_1)}$
- $C_3 = \frac{C_1 (r_1 C_s + G_s + G_{sr})}{G_{sr}}$
- $C_4 = \frac{C_2 (r_2 C_s + G_s + G_{sr})}{G_{sr}}$
- $B = \frac{G_s G_r + G_s G_{sr} + G_r G_{sr}}{C_s C_r}$
- $E = \frac{G_r P_s + G_{sr} P_s + G_{sr} P_r}{C_s C_r}$
- $F = \frac{G_s P_s + G_{sr} P_s + G_{sr} P_r}{C_s C_r}$

III. ESTIMACIÓN DEL VECTOR DE PÉRDIDAS

El incremento de temperatura dentro de un motor de inducción es el resulta de la energía, por unidad de tiempo, que no se logra transformar y se desperdicia como calor. Las potencias perdidas son resultado de un deficiente proceso de conversión de energía eléctrica a mecánica. El modelo térmico presentado en las ecuaciones (5) requiere del cálculo de las potencias perdidas en el estator y rotor $[P_s, P_r]^T$. La potencia total de pérdida se calcula como la diferencia entre la potencia de entrada P_{in} y la de salida P_{out} y esta es igual a la potencia por pérdidas del estator P_s , más la potencia por pérdidas del rotor P_r , más las potencias mecánica y misceláneas que se representa como P_{etc} .

$$P_{in} - P_{out} = P_s + P_r + P_{etc} \quad (7)$$

La potencia por pérdidas del estator P_s es la suma de la potencia de pérdida por efecto Joule en los devanados estatóricos P_{cs} , más la potencia por pérdidas en el núcleo P_{ns} debido al efecto de corrientes parásitas e histéresis.

$$P_s = P_{cs} + P_{ns} \quad (8)$$

$$P_{cs} = R_s(I_a^2 + I_b^2 + I_c^2)(1 + 0.00389(\Delta\theta)) \quad (9)$$

La potencia P_{cs} se calcula como en la ecuación (9), donde R_s es la resistencia estátorica medida a la temperatura de referencia, los términos I_a , I_b , I_c son las corrientes por fase. El término $\Delta\theta$ representa la diferencia de temperatura del devanado estatórico y la temperatura ambiente.

Por otro lado, las potencias por pérdidas del rotor P_r se calculan según la ecuación (10), donde s es un número adimensional que se calcula según la ecuación (11), n_{scr} es la velocidad sincrónica y n_{mec} es la velocidad mecánica del motor.

$$P_r = (P_{in} - P_{cs} - P_{ns})s \quad (10)$$

$$s = \frac{n_{scr} - n_{mec}}{n_{scr}} \quad (11)$$

Luego, la pérdida P_{etc} se podra estimar como:

$$P_{etc} = \chi(P_{in} - P_{out}) \quad (12)$$

donde χ oscila entre $[0, 0.11]$ según datos de [?], se puede calcular de forma experimental por medio de las pérdidas mecánicas y misceláneas. Dado que las ecuaciones (8) y (10) dependen de P_{ns} , es necesario estimarla. Para ello, se sustituye (8), (10) y (12) en (7) para obtener la potencia del núcleo P_{ns} en términos de parámetros medidos:

$$P_{ns} = \frac{(1-s-\chi)P_{in} - (1-s)P_{cs} - (1-\chi)P_{out}}{(1-s)} \quad (13)$$

Nuevamente, al sustituir (13) en (8) y (10) se obtienen expresiones que solamente dependen de las mediciones realizadas. De esta forma las expresiones para P_s y P_r , tomando $\chi = 0$, son aproximadas por las expresiones:

$$P_s \approx P_{in} - \frac{P_{out}}{(1-s)} \quad (14)$$

$$P_r \approx s \frac{P_{out}}{(1-s)} \quad (15)$$

IV. ESTIMACIÓN DE PARÁMETROS

Para estimar los parámetros $[G_s, G_r, G_{sr}, C_s, C_r]^T$ se comparan las respuestas θ_s y θ_r del modelo de referencia basado en 6 con las temperaturas medidas obtenidas del motor, cada segundo a lo largo de cada una de las pruebas, θ_s y θ_r . Los parámetros del modelo de referencia se van ajustando iterativamente de manera tal que la diferencia entre las respuestas de ambos modelos sea mínima, en este sentido, el ajuste de los parámetros es un problema de optimización.

De esa manera, los parámetros de la solución analítica del modelo (6) se van ajustando iterativamente de tal forma que dicha diferencia sea mínima. En este sentido, el ajuste de los parámetros es un problema de optimización donde la función objetivo a optimizar es el error cuadrático medio (16), que se obtiene restando los datos experimentalmente medidos θ y la respuesta $\tilde{\theta}$ del modelo térmico (6).

$$\varepsilon = \frac{1}{N} \sum_{i=0}^N (\theta(t_i) - \tilde{\theta}(t_i))^2 \quad (16)$$

donde $\theta(t_i) = [\theta_s(t_i), \theta_r(t_i)]^T$ y $\tilde{\theta}(t_i) = [\tilde{\theta}_s(t_i), \tilde{\theta}_r(t_i)]^T$, el t_i indica la temperatura correspondiente en el instante i .

Debido a la complejidad del problema los métodos clásicos no son la mejor opción y es necesario aplicar otras estrategias de optimización. Para este tipo de problemas se han propuesto y probado con éxito una gran variedad de algoritmos de optimización bioinspirados como: Genetic Algorithm (GA) [?], inspirados en la ley de sobrevivencia del más fuerte; Particle Swarm (PS), inspirado en el comportamiento social de bandadas de pájaros o cardúmenes de peces; Ant Colony (AC), inspirados en los hábitos alimentarios de colonias de hormigas; Differential Evolution (DE), basado en el principio de selección natural en la supervivencia de especies y, más recientemente, el Artificial Bee Colony, que simula el comportamiento alimenticio de los enjambres de abejas [15].

1) *Artificial Bee Colony (ABC)*: Desde su creación en 2005 este algoritmo ha sido aplicado a la solución de una gran cantidad de problemas de optimización [16]–[18] y se han propuesto muchas variantes del mismo, como un algoritmo de inteligencia de enjambres que emula el comportamiento de las abejas en la búsqueda y explotación de fuentes de alimento. Define una población de fuentes de alimento modificada por medio de abejas artificiales, con el objetivo de determinar los lugares con un alto recurso de alimento [15], [19].

Employed bees explotan las fuentes de alimento, guardan su información y la comunican a onlooker bees, con ello las onlookers bees eligen las mejores fuentes que serán explotadas. Cuando alguna fuente de alimento se agota, scouts bees buscan nuevas fuentes para sustituir la que se agotó.

Las fuentes de alimento representan soluciones factibles del problema de optimización y la cantidad de alimento de la fuente corresponde a la calidad de la solución (fitness), la cual es determinada de acuerdo a la cercanía a la colmena, la cantidad de alimento disponible y la facilidad de extraer el alimento.

Las fuentes de alimento iniciales se generan de forma aleatoria por medio de la siguiente fórmula

$$x_{i,j} = \min_j + \text{rand}(0,1) \cdot (\max_j - \min_j) \quad (17)$$

donde $x_{i,j}$ representa el parámetro j de la fuente de alimento (solución) X_i y \min_j y \max_j son las cotas inferior y superior del parámetro j . ABC se organiza en tres etapas:

- (i) Employed bees determinan nuevas soluciones (fuentes de alimento) mediante la ecuación

$$v_{i,j} = x_{i,j} + \psi(x_{i,j} - x_{k,j}) \quad (18)$$

donde cada $v_{i,j}$ representa una fuente de alimento, ψ es un valor aleatorio con distribución uniforme en el intervalo $[-1,1]$ y k es cualquiera de las fuentes diferente de la fuente i . Se evalúan las soluciones encontradas, se comparan con la solución actual y se conserva la mejor.

- (ii) Cada onlooker bee elige una fuente de alimento X_i con cierta probabilidad P_i , tomando como base el fitness dado por las employed bees. Luego, se calculan nuevas soluciones candidatas por medio de la fórmula (18), se evalúan las soluciones encontradas, se comparan con la solución X_i y se selecciona la mejor.
- (iii) Employed bees con soluciones que no pudieron ser mejoradas se convierten en scout bees, abandonan su solución y buscan nuevas soluciones a partir de la fórmula (17).

Ver algoritmo 1.

Algorithm 1: Artificial Bee Colony Algorithm

```

1  $i \leftarrow 0$ 
2 Initial population:  $\{v_{i,j}\}$ 
3 while  $i \leq \text{iterMax}$  do
4    $i \leftarrow i + 1$ 
5   Employed Phase
6   Onlooker Phase
7   Scout Phase
8   Choose the best solution
9 end
```

2) *Differential Evolution (DE)*: es un algoritmo útil para determinar minimizadores globales de problemas con o sin restricciones, sin el requerimiento de funciones objetivo derivables, continuas, lineales o uniobjetivo. Emula el proceso evolutivo y de supervivencia dado por Genetic Algorithm y Evolutionary Strategies.

Así, dada una población de tamaño $N \geq 4$, donde cada individuo X_i está compuesto por D parámetros, $x_{i,j}^{(k)}$ representa el parámetro j de la solución i en la generación k , donde L_j y U_j son las cotas inferior y superior del parámetro

j , respectivamente. DE determina los valores iniciales de los parámetros de manera aleatoria y aplica los operadores de mutación, cruzamiento y selección a cada vector de parámetros de la siguiente manera, en la k -ésima generación:

- (i) Por cada solución i , se seleccionan otras tres soluciones aleatorias i_1, i_2 e i_3 y calcula su donator vector or donator solution, por medio de la fórmula (19).

$$V_i^{(k+1)} = X_{i_1}^{(k)} + M(X_{i_2}^{(k)} - X_{i_3}^{(k)}) \quad (19)$$

donde M es el differential weight (factor de mutación), calculado de manera aleatoria en el intervalo $[0,2]$.

- (ii) A partir de $X_i^{(k)}$ y $V_i^{(k+1)}$, se genera un trial vector por medio de la siguiente fórmula

$$U_i^{(k+1)} = \begin{cases} V_i^{(k+1)}; & \text{if } \text{rand}_{i,j} \leq P \vee j = I_{\text{rand}} \\ X_i^{(k)}; & \text{otherwise} \end{cases} \quad (20)$$

donde $\text{rand}_{i,j} \sim U[0,1]$ es la crossover probability, P es una probabilidad dada e I_{rand} es un entero aleatorio tomado del conjunto $\{1, 2, 3, \dots, D\}$, por medio del cual se garantiza que $X_i^{(k)} \neq V_i^{(k+1)}$.

- (iii) Se compara el valor objetivo de cada vector con su respectivo trial vector y se toma el que brinda mejor valor, en el caso de minimización será el que genere un menor valor objetivo

$$X_i^{(k+1)} = \begin{cases} U_i^{(k+1)}; & \text{if } f(U_i^{(k+1)}) \leq f(X_i^{(k)}) \\ X_i^{(k)}; & \text{otherwise} \end{cases} \quad (21)$$

Ver algoritmo 2.

Algorithm 2: Differential Evolution Algorithm (DE)

```

1  $k \leftarrow 0$ 
2 Generate initial parameters
3 while  $k \leq \text{genMax}$  do
4   for  $i = 1 : N$  do
5     Mutation
6     Crossover
7     Selection
8   end
9    $k \leftarrow k + 1$ 
10 end
```

V. EXPERIMENTOS

El algoritmo 3 muestra el procedimiento general para el ajuste de parámetros en la predicción de la temperatura del estator y rotor, a partir del modelo térmico.

A. Banco de pruebas y adquisición de datos

Se diseñó y construyó un banco de pruebas para motores trifásicos que se compone de un generador de corriente directa de 5 kW y un banco de resistencias de 7 kW. El banco posee tres autotransformadores monofásicos conectados en estrella para provocar bajos y altos voltajes de alimentación así como desbalances. Además de poleas y fajas para acoplar

Algorithm 3: Algoritmo General

Input: $\{\theta(t_i)\}, tol, iterMax$ **Output:** $[G_s, G_r, G_{sr}, C_s, C_r]^T, \{\tilde{\theta}_s(t_i)\}, \{\tilde{\theta}_r(t_i)\}$

```
1 Calcular  $[P_s, P_r]^T$  (Por medio de (14)-(15))
2 while  $\min\{\varepsilon\} \geq tol \ \& \ iter \leq iterMax$  do
3   Resolver  $\min\{\varepsilon\}$  (Por medio de ABC o DE)
4    $[G_s, G_r, G_{sr}, C_s, C_r]^T \leftarrow \arg \min\{\varepsilon\}$ 
5   Calcular  $\{\tilde{\theta}_s(t_i), \tilde{\theta}_r(t_i)\}$  (Por medio de (6))
6 end
```




Fig. 2. Imagen parcial del banco de pruebas implementado. Tomado de [21]

mecánicamente el motor al generador tal como se aprecia en la Figura 2.

Se desarrolló una solución informática [22] en LabView v12.0 que gestiona el banco de pruebas mediante un controlador de tiempo real C-Rio 9073 y somete los motores a experimentos controlados donde se definen los parámetros de la prueba, se controlan los estímulos del motor (carga del motor, tiempos de encendido o apagado), se monitorea su reacción y finalmente se registran en archivos todas las variables de interés, específicamente voltajes y corrientes trifásicas, torque, velocidad angular y once puntos de temperatura en el motor, entre ellos rodamientos, carcasa, núcleo, devanado. Formando tres conjuntos de datos: pruebas al 50% de carga (C50), al 75% de carga (C75) y al 100% de carga (C100), y cada uno de ellos subdividiéndose de acuerdo a tres características que representan posibles fallas en el motor: cobertor que simula poca ventilación (Cobertor), subvoltaje a 115V (V115), 3% de desbalance (D3) y al 1% de desbalance que simula condiciones nominales (D1).

B. Resultados

Para analizar el comportamiento de los parámetros y de las temperaturas aproximadas del estator y rotor, ante diferentes condiciones y por medio de distintos métodos de optimización,


se minimiza el error cuadrático medio definido en (16) por medio de ABC y DE, en los tres conjuntos de pruebas definidos anteriormente y bajo algunas de las características indicadas, para identificar cada una de las pruebas se utilizan los códigos C50, C75, C100, Cobertor, V115, D3 y D1, según corresponda.

Según las figuras 3(a)-3(j), para el motor al 50% de carga, en la mayoría de los casos, la temperatura del estator es siempre inferior a la del rotor y después del segundo 1500 la diferencia es más notoria. Según las figuras 4(a)-4(h) el comportamiento para el caso del motor al 75% de carga es muy similar al del 50% de carga. Finalmente, según las figuras 5(a)-5(l), para el caso al 100% de carga la temperatura del estator es levemente superior a la del rotor durante los primeros 1000 segundos pero después la relación se invierte.


Por otro lado, en la tabla I se muestran los parámetros obtenidos en todas las pruebas realizadas, según corresponda. Además, se muestra en cada caso el error cuadrático medio alcanzado y el tiempo de en segundos (seg) consumido durante cada ejecución, tanto el método ABC como el DE realizaron siempre 10000 iteraciones.

Analizando y comparando los resultados tanto de las gráficas como de la tabla, es posible observar que en algunos casos no se logra alcanzar un error aceptable, debido a que


- El algoritmo optimizador ha quedado atrapado en algún mínimo local.
- Algunas medidas perdidas, vistas como “ourliers” , producen una gran perturbación en los resultados del algoritmo, como se puede observar en las figuras 3(j), 4(g) y 4(h).
- Dada las condiciones anormales de la prueba, no se logró ejecutar la prueba con suficiente tiempo (al menos 5000 segundos) para su adecuado análisis, como es el caso de los resultados de la figura 5(l) el cual combina dos tipos de falla Subvoltaje+Cobertor.




(a)




(b)




(c)




(d)




(e)




(f)




(g)



(h)




(i)




(j)

Fig. 3. Resultados al 50% de carga


Rotor: –Valores medidos; o Valores aproximados con ABC; + Valores aproximados con DE
 Estator: –Valores medidos; o Valores aproximados con ABC; + Valores aproximados con DE




(a)




(b)




(c)




(d)




(e)



(f)




(g)




(h)

Fig. 4. Resultados al 75% de carga


Rotor: –Valores medidos; o Valores aproximados con ABC; + Valores aproximados con DE
 Estator: –Valores medidos; o Valores aproximados con ABC; + Valores aproximados con DE




(a)




(b)




(c)




(d)




(e)




(f)




(g)




(h)




(i)



(j)



(k)



(l)

Fig. 5. Resultados al 100% de carga

Rotor: –Valores medidos; o Valores aproximados con ABC; + Valores aproximados con DE
 Estator: –Valores medidos; o Valores aproximados con ABC; + Valores aproximados con DE

Prueba	$C_r^{(ABC)}$	$C_s^{(ABC)}$	$G_r^{(ABC)}$	$G_s^{(ABC)}$	$G_{sr}^{(ABC)}$	Error ^(ABC)	Seg ^(ABC)	$C_r^{(DE)}$	$C_s^{(DE)}$	$G_r^{(DE)}$	$G_s^{(DE)}$	$G_{sr}^{(DE)}$	Error ^(DE)	Seg ^(DE)
C50D10306	304.4060	7351.1353	0.0982	4.5963	0.3761	0.1858	1216.5306	4910.8505	0.0000	-26.7982	38.6562	128.1560	0.0977	12.8130
C50D1090616	265.2343	7269.3058	0.0123	4.6296	0.8866	0.2066	1209.0922	68.2037	7510.3794	-27.1155	37.7305	151.3220	0.2104	12.7770
C50D1230816	345.2435	6938.3024	0.0724	5.2916	0.4057	1.2693	1229.2766	5511.9735	0.0000	-13.8820	21.9362	81.8741	1.5326	12.7220
C50D3240816	0.0000	8356.0741	0.1796	5.1118	0.0433	9.2083	1120.2232	0.0000	12728.7459	-1.3825	8.0497	5.2826	14.4423	11.8390
C50D3300816	179.9390	6970.2236	0.0000	4.9726	1.0842	2.1766	1209.0026	4358.8016	0.0000	-14.4675	23.0494	74.3482	1.8943	12.8340
C50D3310816	219.6418	7645.8706	0.0000	4.9516	1.0415	1.5240	1204.7294	4827.4287	5.2450	-559.5193	709.9562	2713.1322	1.6852	12.8559
C50D1V115011116	498.1428	6192.4489	0.0000	4.3715	1.7096	0.1135	1206.1359	0.0000	6970.4548	-7.2260	13.3521	38.6725	0.1101	12.7937
C50D1V115261016	496.8256	6203.2686	0.1121	4.2099	0.7987	0.1176	1234.9180	3978.9320	54.9733	-128.0533	174.8739	515.4338	0.1103	12.8630
C50D1V115270916	634.0673	4751.2076	0.0460	5.3110	0.9360	0.8508	1237.7928	3738.9955	0.0000	-3.2316	9.4737	14.8817	0.4304	12.9499
C50D1V115280916	0.0000	7825.5081	0.2975	4.8136	0.0786	13.9670	1121.5485	0.0000	13330.4600	-37.2175	61.9287	112.2374	40.1331	12.0166
C75D1060616	676.8773	6722.5513	0.1183	4.2115	1.0569	0.5224	1213.7523	4888.6604	0.0000	-10.5084	17.6724	51.0705	0.2611	12.5564
C75D1160816	660.6468	8353.9510	0.0000	4.5705	1.6143	0.4568	1198.2374	5697.3522	0.0000	-17.1155	26.4387	80.3776	0.2688	13.1239
C75D1170816	678.4432	7435.7541	0.0000	4.5354	1.9723	0.2092	1204.3057	0.3053	8449.2121	-156.3273	199.9886	783.0111	0.2146	13.1259
C75D1V230160816	660.6468	8353.9509	0.0000	4.5705	1.6143	0.4568	1205.1950	5679.1863	0.0000	-16.5226	25.7083	77.3839	0.2667	12.8959
C75D1V230170816	678.4432	7435.7541	0.0000	4.5354	1.9723	0.2092	1203.6650	5334.4933	0.8355	-28.1474	39.8705	140.4713	0.1752	12.9173
C75D1V115130916	1045.5636	6419.3112	0.0000	4.5272	2.4607	0.0957	1212.1679	4863.4768	661.1312	-14.4190	22.3538	76.8131	0.1365	12.9434
C75D1V115140916	893.9542	6534.9229	0.0000	4.5206	2.2324	7.5676	1199.5404	4858.8865	0.0034	-18.6293	28.4143	86.6830	7.4976	12.8930
C75D1Cobertor191016	2292.8720	6312.4277	0.1043	4.4518	0.0000	2206.2509	1203.1974	2416.8245	8028.3752	-851.8439	1090.0212	3949.2769	2248.0109	13.0835
C100D1090816	1036.5821	7230.3321	0.2047	3.8914	1.3188	1.1840	1219.4474	5452.6292	0.0000	-9.3944	16.1288	45.6795	0.5905	13.1137
C100D1100816	1352.7135	6324.0926	0.4286	3.4878	0.7069	1.3144	1222.5688	5598.2444	0.0000	-4.9949	10.1868	28.2030	0.4838	13.0267
C100D1200616	991.0357	7083.4516	0.0000	3.9341	2.1060	1.8938	1208.3015	4962.3376	0.0000	-10.9427	18.4254	46.8692	1.2888	12.7372
C100D3041016	1033.1381	6412.7535	0.1306	4.2260	1.8153	0.1111	1227.9621	1690.2383	5496.7148	-4.7138	10.2737	25.9374	0.1613	13.3798
C100D4021116	1191.2173	5514.3069	0.2703	3.8593	1.6069	0.1997	1224.0262	4378.9550	304.5515	-15.7563	24.5243	72.7618	0.1674	13.1596
C100D1V115210916	1445.8455	5086.5362	0.0000	4.0680	2.9692	0.1455	1204.8580	4642.5705	0.0000	-143.6488	188.3879	653.6874	0.4099	12.9725
C100D1ConCobertor060916	1283.8446	6365.9285	0.0000	3.9616	2.3464	0.2608	1208.5188	3133.7022	3581.4309	-5.4192	10.8409	27.4613	0.4931	13.3150
C100D1ConCobertor070916	1135.3822	6157.2810	0.0000	4.1533	2.4210	1.5795	1203.6150	4877.6969	193.7552	-11.2258	18.4009	55.0012	1.3889	12.8320
C100D1ConCobertor170616	1303.2684	6232.0063	0.2991	3.4650	0.9873	0.5121	1198.9387	5392.9871	0.0000	-7.3149	13.0264	37.3636	0.5335	12.5997
C100D1ConCobertor111016	1068.6106	6644.9930	0.4202	3.7733	0.4960	0.5493	1233.7727	5380.9066	0.0000	-9.8974	16.6751	51.4621	0.2606	13.0104
C100D1ConCobertor121016	936.6124	6841.6641	0.3140	3.8345	0.6774	0.1544	1227.2276	5278.1819	0.0000	-34.3424	47.6255	166.5368	0.1372	13.0473
C100D1V115Cobertor201016	465.1248	5767.6490	0.4109	4.0045	0.6823	3.3984	1221.1092	436.4044	5382.1810	0.0325	4.9524	1.5667	7.4231	14.0963

TABLE I
PARÁMETROS OBTENIDOS POR ABC Y DE EN CADA UNA DE LAS PRUEBAS REALIZADAS

VI. CONCLUSIONES

Se comprobó que es posible utilizar técnicas bioinspiradas para estimar los parámetros térmicos del modelo propuesto y con ellos la temperatura del rotor de la máquina, esto sin necesidad de conocer características físicas, materiales, etc., del motor en estudio. Además, tomando como criterio de exclusión aquellos errores mayores a 0.5 en cada una de las pruebas realizadas, es posible observar en la tabla I que tomando como función objetivo al error cuadrático medio obtenido entre las mediciones realizadas al motor y las obtenidas por medio de la solución exacta del modelo definido en (5), los algoritmos evolutivos logran determinar óptimos locales y no globales. Sin embargo, en las figuras 3, 4 y 5 se puede notar que con los parámetros obtenidos (independientemente de si son óptimos locales o globales) los resultados del modelo se ajustan de manera adecuada a las mediciones realizadas al motor, en cada uno de los casos.

ACKNOWLEDGMENT

Los autores agradecen a la Vicerrectoría de Investigación del Instituto Tecnológico de Costa Rica por el apoyo dado al proyecto Sistema Experto para Motores Asistido por Temperatura (SEMAT) código: VIE 5402-1341-1301.

REFERENCES

- [1] H. Oraee. *A quantitative approach to estimate the life expectancy of motor insulation systems*. IEEE Trans. Dielectr. Electr. Insul., vol. 7, no. 6, pp. 790-796, 2000.
- [2] P. Pillay and M. Manyage. *Loss of life in induction machines operating with unbalanced supplies* IEEE Trans. Energy Convers., vol. 21, no. 4, pp. 813-822, 2006.
- [3] Z. Gao. *Sensorless Stator Winding Temperature Estimation for Induction Machines*. Georgia Institute of Technology, 2006.
- [4] S.E. Zocholl. *Comparing motor thermal models*. in In 31st Annual Western Protective Relay Conference, 2004, pp. 1-10.
- [5] G. Kylander. *Thermal modelling of small cage induction motors*. Chalmers University of Technology, 1995.
- [6] A.L. Shenkman and M. Chertkov. *Experimental method for synthesis of generalized thermal circuit of polyphase induction motors*. IEEE Trans. Energy Convers., vol. 15, no. 3, pp. 264-268, 2000.
- [7] B. Dutta and S.K. Chowdhury. *Steady state thermal model of TEFC induction machine*. in IEEE International Conference on Emerging Technologies and Factory Automation, ETFAPower Electronics, Drives and Energy Systems (PEDES), 2012, pp. 1-6.
- [8] M.J. Duran and J. Fernandez. *Lumped-Parameter Thermal Model for Induction Machines*. IEEE Transactions on Energy Conversion, vol. 19, pp. 791-792, 2004.
- [9] J.F. Moreno, F.P. Hidalgo and M.D. Martinez. *Realisation of tests to determine the parameters of the thermal model of an induction machine*. IEE Proceedings - Electric Power Applications, vol. 148. p. 393, 2001.
- [10] *IEEE Standard Test Procedure for Polyphase Induction Motors and Generators*. IEEE Std 112-2004 (Revision IEEE Std 112-1996), pp. 01-79, 2004.
- [11] I. Boldea and S.A. Nasar. *The Induction Machine Handbook*. CRC Press, 2002.
- [12] S. Bin Lee and T.G. Habetler. *An online stator winding resistance estimation technique for temperature monitoring of line-connected induction machines*. IEEE Trans. Ind. Appl., vol. 39, no. 3, pp. 685-694, 2003.
- [13] Z. Gao, T. G. Habetler, R. G. Harley, and R. S. Colby. *An Adaptive Kalman Filtering Approach to Induction Machine Stator Winding Temperature Estimation Based on a Hybrid Thermal Model*. IEEE Ind. Appl. Conf., pp. 2-9, 2005.
- [14] K. Cho and J. Seok. *Induction Motor Temperature Estimation Based on High-Frequency Model of Rotor Bar* in Industry Applications Society Annual Meeting, 2008. IAS 08. IEEE, 2008, no. 1, pp. 1-7.
- [15] D. Karaboga, B. Gorkemli, C. Ozturk and N. Karaboga. *A comprehensive survey: artificial bee colony (ABC) algorithm and applications*. Artif. Intell. Rev., vol. 41, no. 1, pp. 21-57, 2014.
- [16] D. Karaboga and B. Akay. *Artificial Bee Colony (ABC) Algorithm on Training Artificial Neural Networks*. in 2007 IEEE 15th Signal Processing and Communications Applications, 2007.
- [17] D. Karaboga and C. Ozturk. *Fuzzy clustering with artificial bee colony algorithm*. Sci. Res. Essays, vol. 5, no. 14, pp. 1899-1902, 2010.
- [18] K.S. Kaswan, S. Choudhary and K. Sharma. *Applications of Artificial Bee Colony Optimization technique: Survey in Applications of Artificial Bee Colony Optimization technique: Survey*, 2015, pp. 1660-1664.
- [19] T. Liao, D. Aydn and T. Sttze. *Artificial bee colonies for continuous optimization: Experimental analysis and improvements*. Swarm Intell., vol. 7, no. 4, pp. 327-356, 2013.
- [20] A. Boglietti, A. Cavagnino, M. Lazzari, and M. Pastorelli. *A Simplified Thermal Model for Variable-Speed Self-Cooled Industrial Induction Motor*. IEEE Trans. Ind. Appl., vol. 39, no. 4, pp. 945-952, 2003.
- [21] L.D. Murillo-Soto and G. Figueroa-Mata. *Obtención de parámetros de un modelo térmico para un motor trifásico usando algoritmos genéticos* in 13th LACCEI Annual International Conference, 2015, pp. 1-2.
- [22] L.D. Murillo-Soto. *Aplicación informática para el monitoreo de variables eléctricas, mecánicas y térmicas en motores trifásicos de inducción* in Latin American and Caribbean Conference for Engineering and Technology (LACCEI-2014), 2014.

Análisis estadístico de una red de sensores de temperatura para un motor eléctrico de inducción

Geovanni Figueroa-Mata
Escuela de Matemática
Instituto Tecnológico de Costa Rica
Cartago, Costa Rica 159-7050
Email: gfigueroa@itcr.ac.cr

Abstract—Se realiza un análisis estadístico de las mediciones de temperatura promedio capturadas mediante diez sensores instalados en un motor eléctrico de inducción, con el objetivo de comprobar la igualdad estadística de sus medias. Del análisis se concluye que las diez mediciones se pueden agrupar en cuatro grupos con temperaturas promedio estadísticamente iguales. Esto permite reducir la cantidad de sensores a utilizar y distingue cuatro zonas térmicas de importancia en el motor, a saber: devanado, núcleo, eje y carcasa, información que puede ser de utilidad al desarrollar modelos térmicos.

I. INTRODUCTION

Los motores eléctricos de inducción representan la principal fuerza motriz para accionar los sistemas electromecánicos, por lo que estimar de forma correcta la temperatura interna de la máquina es de vital importancia debido a las implicaciones que esto tiene sobre la vida útil de la máquina. Los materiales y barnices aislantes del motor se degradan de forma exponencial, por cada 10°C por encima de la temperatura máxima de la clase del aislamiento, la vida útil se reduce a la mitad [1], [2].

La estimación de la temperatura interna del motor puede realizarse mediante el uso de modelos térmicos mallados para estados transitorios. En general, este tipo de modelos tienen la forma:

$$C \frac{\partial \Theta}{\partial t} = P - G \Theta, \quad (1)$$

donde C es una matriz diagonal que contiene las capacitancias térmicas de la máquina, G es una matriz que contiene las conductancias térmicas entre nodos y P es un vector que contiene las pérdidas de la máquina.

Este tipo de modelos permite predecir la temperatura en un punto específico de la máquina, tanto en régimen transitorio como en estado estable, pero en general, la estimación de los parámetros térmico: C , G y P es compleja [3], [4].

La cantidad de nodos ha utilizar en los modelos mallados para estados transitorios es un factor crítico, pues de ello depende su complejidad y la posible determinación de los parámetros térmicos. En este sentido, es deseable tener la menor cantidad de nodos que mejor describan térmicamente la máquina.

Con la idea de desarrollar un modelo térmico mallado para estados transitorios [5] se propuso inicialmente una red de once sensores los cuales pueden ser reducidos a cuatro, luego de un análisis estadísticos de sus temperaturas promedio.

El artículo esta organizado de la siguiente forma: en la sección II se describe el banco de pruebas y el sistema de adquisición de datos desarrollado; en la sección III se describen las características del motor en estudio; la sección IV detalla los experimentos realizados y en la sección V se hace un análisis de los resultados.

II. BANCO DE PRUEBAS Y SISTEMA DE ADQUISICIÓN DE DATOS

El banco de pruebas para motores trifásicos que se construyó se compone de un generador de corriente directa de 5 kW y un banco de resistencias de 7 kW. El banco posee tres autotransformadores monofásicos conectados en estrella para provocar bajos y altos voltajes de alimentación así como desbalances. En la figura 1 se muestra una fotografía del banco de pruebas implementado.




Fig. 1. Banco de pruebas implementado.

Complementariamente se construyó un sistema de adquisición de datos, el cual se muestra en la figura 2, aquí las flechas indican la dirección del flujo de información en el sistema.

Para interconectar ambos sistemas: el banco de pruebas y el sistema de adquisición de datos se desarrolló una aplicación informática [6] que gestiona el banco de pruebas y somete los motores a experimentos controlados en donde se definen los parámetros de la prueba. La aplicación controlan los estímulos del motor (carga del motor, tiempos de encendido o apagado),

se monitorea su reacción y finalmente se registran todas las variables de interés.

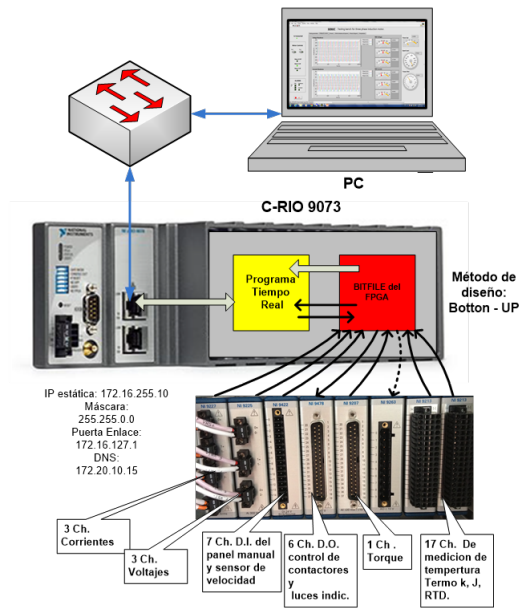


Fig. 2. Sistema de Adquisición de datos.

La aplicación posee una arquitectura cliente-servidor punto a punto y se compone de dos programas uno que se ejecuta en una computadora personal y el otro en un controlador de tiempo real C-RIO 9073 de National Instruments, tal como se muestra en la 2. Los siete módulos que posee instalados el C-RIO son: un NI-9227 para corrientes trifásicas, un NI-9225 para voltajes trifásicos, un NI-9422 para entradas digitales, un NI-9478 salidas digitales, un NI-9207 para entradas analógicas de voltaje, un NI-9263 para salidas analógicas, un módulo NI-9219 universal para RTD y un NI-9213 para termopilas j y k.

El programa que se ejecuta en la PC se conecta mediante una red Ethernet usando el protocolo TCP/IP al controlador C-RIO 9073. Este controla el encendido y apagado del motor seleccionado, muestra las señales trifásicas de corrientes, voltajes, brinda los valores de torque y velocidad angular del eje. Además, muestra en una gráfica la evolución de las once mediciones de temperaturas del motor segregadas de la siguiente forma: las temperaturas de cada devanado del motor trifásico, la medición de temperatura de cada rodamiento, dos temperaturas en el núcleo, tres temperaturas en la carcasa y la temperatura ambiental.

Además, la aplicación de la PC calcula los valores RMS de corriente y voltaje trifásicos, así como el contenido espectral de las señales. Adicionalmente se calculan los ángulos de fase, las potencias de entrada y salida del motor, calcula y gráfica la evolución de la eficiencia de la máquina, calcula el desbalance de la red, el contenido armónico de voltaje y corrientes, así como las potencias reactivas, aparentes y el factor de potencia. Este programa permite exportar todas las 28 variables capturadas en dos tipos de archivos de extensión lvm.

El programa que se ejecuta en el C-RIO configura cada uno de los ocho módulos del sistema, su frecuencia de muestreo,

la sincronización entre módulos de adquisición, el tratamiento de los datos (filtrado), la conversión de datos crudos a variables con significado físico (escalamiento), etc. El controlador manipula salidas digitales para señalización externa, control de contactores y control de un relé de estado sólido mediante modulación de ancho de pulso para el control de la carga eléctrica del generador, que a su vez se traduce en carga mecánica en el motor. El programa del C-RIO implementa protecciones de sobrecarga, de desbalance del voltaje y a valores de contenido armónico superiores a un umbral predefinido por el usuario.

III. CASO DE ESTUDIO

El motor en estudio es de marca Baldor, trifásico, de 2 hp, 230 V y 60 Hz. En el cuadro I se muestran los datos de placa. Se instalaron en el motor cinco termopilas K, tres en la carcasa (CarcasaAbanico, CarcasaCentro y CarcasaEje) dos en el núcleo (Nucleo1 y Nucleo2), además de dos termopilas J en los rodamientos (RolEje y RolAbanico) y tres RTD's en devanado (RTDA, RTDB y RTDC), para un total de once puntos de medición, incluyendo la temperatura ambiente.




Fig. 3. Ubicación de los sensores instalados al motor.

CAT.NO	CEBM3558T						
SPEC.	35E567N909G2						
HP	2						
VOLTS	230/460						
AMP	5.8/2.9						
RPM	1755						
FRAME	145TC	HZ	60	PH	3		
SER.F	1.15	CODE	L	DES	B	CL	F

TABLE I
DATOS DE PLACA DEL MOTOR EN ESTUDIO.

En la figura 5 se muestra la ubicación de cada uno de los sensores que fueron instalados.

IV. DISEÑO DEL EXPERIMENTO

Se realizaron seis pruebas al 100% de carga, completamente al azar durante las cuales se registró segundo a segundo y por un período de 2 horas 30 minutos las diez mediciones de temperatura, esto generó alrededor de 9000 mediciones por

cada sensor. Entre prueba y prueba se dispuso de un lapso de tiempo para que el motor se enfrié, es decir, alcance la temperatura ambiente. A partir de las mediciones se obtuvo la temperatura promedio para cada sensor, las cuales se muestran en el cuadro II. Así, por ejemplo, en la sexta prueba la temperatura promedio registrada en el sensor T_7 fue de $45.2^{\circ}C$.

S_1	S_2	S_3	S_4	S_5	S_6	S_7	S_8	S_9	S_{10}
44.8	28.3	27.2	28.7	40.1	55.6	49.0	63.3	65.0	85.7
39.7	25.5	22.1	25.4	36.2	51.0	44.4	56.7	58.3	60.7
36.7	23.9	19.5	27.0	31.6	43.5	53.9	52.4	53.8	56.4
42.5	27.7	23.7	30.9	36.9	49.9	47.7	60.7	62.5	65.0
38.7	25.4	22.5	28.2	33.2	45.8	43.6	55.1	56.8	59.5
38.4	24.9	21.9	27.0	33.8	49.8	45.2	55.3	57.0	59.6

TABLE II
TEMPERATURA PROMEDIO REGISTRADAS POR CADA SENSOR.

Donde

- S_1 :temperatura promedio del sensor: RolEje.
- S_2 :temperatura promedio del sensor: RolAbanico.
- S_3 :temperatura promedio del sensor: CarcasaAbanico.
- S_4 :temperatura promedio del sensor: CarcasaCentro.
- S_5 :temperatura promedio del sensor: CarcasaEje.
- S_6 :temperatura promedio del sensor: Nucleo1.
- S_7 :temperatura promedio del sensor: Nucleo2.
- S_8 :temperatura promedio del sensor: RTDA.
- S_9 :temperatura promedio del sensor: RTDB.
- S_{10} :temperatura promedio del sensor: RTDC.

V. RESULTADOS

Al aplicar la técnica ANOVA de un factor (temperatura) con la hipótesis nula de igualdad de medias para las temperaturas de los sensores y un nivel de significancia de $\alpha = 0.05$ se obtuvo los resultados que se muestran en la tabla de análisis de varianza III. Los cálculos han sido realizados con en software Minitab.

Fuente	DF	Adj SS	Adj MS	Valor F	Valor p
Sensor	9	11110.6	1234.51	109.03	0
Error	50	566.1	11.23	11.32	
Total	59	11676.1			

TABLE III
ANOVA PARA LOS SENSOR.

Dado que el valor de $p = 0 < 0.05$ se rechaza la hipótesis nula, por lo que existen al menos dos sensores cuyas medias son diferentes.

Para identificar en que grupos se han producido las diferencias se aplicó la prueba de comparación múltiple de Tukey con un 95% de confianza. Los resultados se muestran en el cuadro IV.

prueba de comparacin mltiple de Tukey

El cuadro IV sugiere que respecto a sus medias los sensores pueden ser agrupados en cuatro grupos, los cuales corresponden a zonas específicas de motor:

- Devanado: RTDA, RTDB y RTDC.

Sensor	Ubicación	N	Media	Grupo
S_{10}	RTDC	6	61.42	A
S_9	RTDB	6	58.90	A
S_8	RTDA	6	57.25	A
S_6	Nucleo1	6	49.27	B
S_7	Nucleo2	6	47.28	B
S_1	RolEje	6	40.13	C
S_5	CarcasaEje	6	35.30	C
S_4	CarcasaCentro	6	27.87	D
S_2	RolAbanico	6	25.95	D
S_3	CarcasaAbanico	6	22.67	D

TABLE IV
COMPARACIÓN DE PARES DE MEDIAS POR SENSOR.

- Núcleo: Nucleo1 y Nucleo2.
- Eje: RolEje y CarcasaEje.
- Carcasa: CarcasaCentro, RolAbanico y CarcasaAbanico.

En el cuadro V se muestra la media, desviación estándar y intervalo de confianza para cada uno de los sensores.

Sensor	N	Mean	StDev	95% CI
1	6	40,13	2,98	(37,37; 42,89)
2	6	25,950	1,697	(23,191; 28,709)
3	6	22,67	2,64	(19,91; 25,43)
4	6	27,867	1,876	(25,107; 30,626)
5	6	35,30	3,06	(32,54; 38,06)
6	6	49,27	4,22	(46,51; 52,03)
7	6	47,28	3,84	(44,52; 50,04)
8	6	57,25	4,02	(54,49; 60,01)
9	6	58,90	4,11	(56,14; 61,66)
10	6	61,42	4,00	(58,66; 64,18)

TABLE V
RESUMEN DE MEDIAS.

Por último, en el cuadro VI se resumen los porcentajes de error: R-cuadrado, R-cuadrado ajustado y R-cuadrado pronosticado del método, lo cual nos dice que el modelo se ajusta en un 94.28% a los datos.

S	R-sq	R-sq(adj)	R-sq(pred)
3.36494	95.15%	94.28%	93.02%

TABLE VI
PORCENTAJES DE ERROR ON ONCE SENSOSES.

Al ejecutar de nuevo la técnica ANOVA únicamente con los sensores S_1 , S_4 , S_6 y S_{10} (elegidos por tener la temperatura promedio más alta de cada grupo), los porcentajes de error se muestran en el cuadro VII

S	R-sq	R-sq(adj)	R-sq(pred)
3.39991	94.01%	93.11%	91.37%

TABLE VII
PORCENTAJES DE ERROR CON CUATRO SENSOSES.

Observe que la diferencia del porcentaje de error R-cuadrado ajustado es de menos del 1.5%, pasando de 94.28% a 93.11%, cuadros VI y VII.

En la figura 6 se muestran los gráficos de probabilidad normal de los residuos, histograma de residuos, residuos

versus ajuste y aleatoriedad de residuos, los cuales indican que los residuos se distribuyen normalmente, son aleatorios y no correlacionados.

VI. CONCLUSIONES

El análisis estadístico permitió agrupar los sensores de acuerdo a su medición de temperatura promedio en cuatro grupos, los cuales corresponden a zonas específicas del motor: Devanado, Núcleo, Eje y Carcasa. Esto sugiere que se puede reducir el número de sensores instalados de once a cuatro, a saber: RTDC (S_{10}), Nucleo1 (S_6), RolEje (S_1) y CarcasaCentro (S_4) sin una pérdida significativa en la descripción térmica de la máquina.

REFERENCES

- [1] A. E. Emanuel, "A quantitative approach to estimate the life expectancy of motor insulation systems," *IEEE Transactions on Dielectrics and Electrical Insulation*, vol. 9, pp. 627–628, Aug 2002.
- [2] P. Pillay and M. Manyage, "Loss of life in induction machines operating with unbalanced supplies," *IEEE Transactions on Energy Conversion*, vol. 21, pp. 813–822, Dec 2006.
- [3] J. F. Moreno, F. P. Hidalgo, and M. D. Martinez, "Realisation of tests to determine the parameters of the thermal model of an induction machine," *IEE Proceedings - Electric Power Applications*, vol. 148, pp. 393–397, Sep 2001.
- [4] M. J. Duran and J. Fernandez, "Lumped-parameter thermal model for induction machines," *IEEE Transactions on Energy Conversion*, vol. 19, pp. 791–792, Dec 2004.
- [5] L. Murillo-Soto, G. Figueroa-Mata, and O. Guerrero-Castro, "Identificación de parámetros de un modelo térmico para un motor trifásico de inducción usando algoritmos genéticos," *Revista Tecnología en Marcha*, vol. 29, no. 5, pp. 25–41, 2016.
- [6] L. Murillo-Soto, "Aplicación informática para el monitoreo de variables eléctricas, mecánicas y térmicas en motores trifásicos de inducción," in *Proceedings of the Twelfth Latin American and Caribbean Conference for Engineering and Technology* (M. M. L. Petrie, H. Alvarez, and C. R. Arroyave, eds.), July 2014.

Estimación de la temperatura del rotor de un motor eléctrico de inducción

Geovanni Figueroa-Mata
Escuela de Matemática
Instituto Tecnológico de Costa Rica
Cartago, Costa Rica 159-7050
Email: gfigueroa@itcr.ac.cr

Abstract—Mediante sensores se registra la temperatura en diez puntos específicos de un motor eléctrico de inducción. Luego por medio de un análisis ANOVA se logra agrupar estos diez puntos en cuatro grupos, los cuales corresponden a cuatro zonas térmicas de interés del motor, a partir de las cuales se genera una estimación para la temperatura del rotor. La estimación se valida comparandola con las mediciones obtenidas mediante una pistola láser.

I. INTRODUCTION

Los motores eléctricos de inducción son la principal fuerza motriz para accionar los sistemas electromecánicos, por lo que estimar de forma correcta su temperatura interna es de vital importancia por las implicaciones que esto tiene sobre la vida útil de la máquina [1]. Los materiales y barnices aislantes del motor se degradan de forma exponencial. Por cada 10°C por encima de la temperatura máxima de la clase del aislamiento, la vida útil se reduce a la mitad:

$$L_x = L_{100} 2^{(T_c - T_x)/k},$$

donde L_x representa la estimación de la vida útil en la nueva condición de operación, L_{100} es la vida útil proyectada de fábrica, usualmente 20.000 horas, T_x es la nueva temperatura de operación, T_c es la temperatura de la clase del aislamiento y k es una constante definida para cada clase de aislamiento [2].

Existen varios métodos para estimar la temperatura interna de un motor, una de ellas es mediante el uso de modelos térmicos mallados para estados transitorios. En general, este tipo de modelos tienen la forma:

$$C \frac{\partial \Theta}{\partial t} = P - G \Theta, \quad (1)$$

donde C es una matriz diagonal que contiene las capacitancias térmicas de la máquina, G es una matriz que contiene las conductancias térmicas entre nodos y P es un vector que contiene las pérdidas de la máquina.

Este tipo de modelos permite estimar la temperatura en un punto específico de la máquina, tanto en régimen transitorio como en estado estable, pero en general la estimación de los parámetros térmicos C , G y P es compleja, pues requiere conocer los materiales, la geometría, las dimensiones y masas de la máquina [3]–[7].

Otra alternativa es estimar las resistencias estáticas (R_1) y rotóricas (R_2) y usarlas para estimar la temperatura del rotor θ_2 a partir de la ecuación

$$\theta_2 = \frac{R_2}{R_1} (\theta_1 + k) - k, \quad (2)$$

Aquí, R_1 representa la resistencia a la temperatura θ_1 , usualmente medido a temperatura ambiente con motor apagado, R_2 la resistencia a la temperatura θ_2 y k es el coeficiente del material conductor, que para el cobre es 234.5 y para el aluminio es de 225 [8]. La desventaja que presenta este método es que la estimación de la resistencia estática requiere ser invasiva.

Este artículo presenta otra forma de estimar la temperatura interna de la máquina. Para esto se instalaron 10 sensores sobre un motor eléctrico de inducción. Se aplicó un análisis de varianza (ANOVA) sobre las mediciones promedio de temperatura reportadas por cada uno de los sensores, el cual permitió identificar cuatro zonas térmicas de interés en la motor y a partir de las cuales se hace una estimación numérica de la temperatura interna de la máquina. Dicha estimación se compara con las mediciones obtenidas por medio de una pistola láser.

El artículo está organizado de la siguiente forma: en la sección II se describe el banco de pruebas y el sistema de adquisición de datos desarrollado, en la sección III se describen las características del motor en estudio; en la sección IV se detalla los experimentos realizados, en la sección V se describe el análisis de varianza y los resultados, en la sección VI se presenta la estimación numérica de la temperatura del rotor y en la sección VII se compara la estimación con las mediciones obtenidas por medio de una pistola láser.

II. BANCO DE PRUEBAS Y SISTEMA DE ADQUISICIÓN DE DATOS

El banco de pruebas para motores trifásicos que se construyó se compone de un generador de corriente directa de 5 kW y un banco de resistencias de 7 kW. El banco posee tres autotransformadores monofásicos conectados en estrella para provocar bajos y altos voltajes de alimentación así como desbalances. En la figura 1 se muestra una fotografía del banco de pruebas implementado.

Complementariamente se construyó un sistema de adquisición de datos, el cual se muestra en la figura 2.




Fig. 1. Banco de pruebas implementado.

Para interconectar ambos sistemas: el banco de pruebas y el sistema de adquisición de datos se desarrolló una aplicación informática [10] que gestiona el banco de pruebas y somete los motores a experimentos controlados en donde se definen los parámetros de la prueba. La aplicación controla los estímulos del motor (carga del motor, tiempos de encendido o apagado, etc.), se monitorea su reacción y finalmente se registran todas las variables de interés.

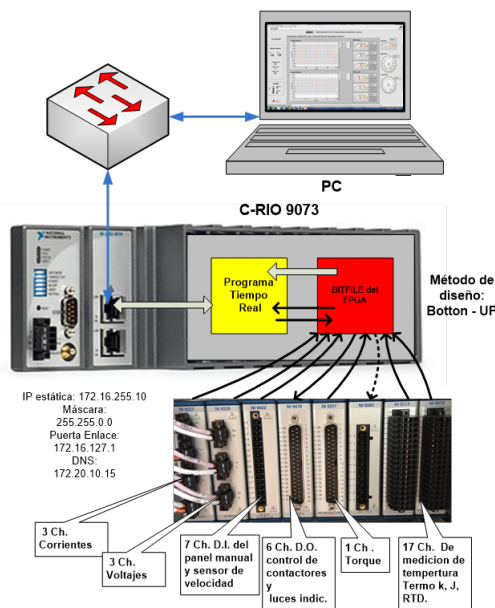


Fig. 2. Sistema de Adquisición de datos.

La aplicación posee una arquitectura cliente-servidor punto a punto y se compone de dos programas uno que se ejecuta en una computadora personal y el otro en un controlador de tiempo real C-RIO 9073 de National Instruments, tal como se muestra en la 2. Los siete módulos que posee instalados el C-RIO son: un NI-9227 para corrientes trifásicas, un NI-9225 para voltajes trifásicos, un NI-9422 para entradas digitales, un NI-9478 salidas digitales, un NI-9207 para entradas analógicas de voltaje, un NI-9263 para salidas analógicas, un módulo NI-

9219 universal para RTD y un NI-9213 para termopilas j y k.

El programa que se ejecuta en la PC se conecta mediante una red Ethernet usando el protocolo TCP/IP al controlador C-RIO 9073. Este controla el encendido y apagado del motor, muestra las señales trifásicas de corrientes, voltajes, brinda los valores de torque y velocidad angular del eje. Además, muestra en una gráfica la evolución de las once mediciones de temperaturas del motor segregadas de la siguiente forma: las temperaturas de cada devanado del motor trifásico, la medición de temperatura de cada rodamiento, dos temperaturas en el núcleo, tres temperaturas en la carcasa y la temperatura ambiental.

Además, la aplicación de la PC calcula los valores RMS de corriente y voltaje trifásicos, así como el contenido espectral de las señales. Adicionalmente se calculan los ángulos de fase, las potencias de entrada y salida del motor, calcula y gráfica la evolución de la eficiencia de la máquina, calcula el desbalance de la red, el contenido armónico de voltaje y corrientes, así como las potencias reactivas, aparentes y el factor de potencia. Este programa permite exportar todas las 28 variables capturadas en dos tipos de archivos de extensión lvm.

El programa que se ejecuta en el C-RIO configura cada uno de los ocho módulos del sistema, su frecuencia de muestro, la sincronización entre módulos de adquisición, el tratamiento de los datos (filtrado), la conversión de datos crudos a variables con significado físico (escalamiento), etc. El controlador manipula salidas digitales para señalización externa, control de contactores y control de un relé de estado sólido mediante modulación de ancho de pulso para el control de la carga eléctrica del generador, que a su vez se traduce en carga mecánica en el motor. El programa del C-RIO implementa protecciones de sobrecarga, de desbalance del voltaje y a valores de contenido armónico superiores a un umbral predefinido por el usuario.

III. CASO DE ESTUDIO

El motor en estudio es de marca Baldor, trifásico, de 2 hp, 230 V y 60 Hz. En la figura 3 se muestran los datos de placa del motor. Se instalaron en el motor cinco termopilas K, tres en la carcasa (CarcasaAbanico, CarcasaCentro y CarcasaEje) dos en el núcleo (Nucleo1 y Nucleo2), además de dos termopilas J en los rodamientos (RolEje y RolAbanico) y tres RTD's en devanado (RTDA, RTDB y RTDC), para un total de once puntos de medición, incluyendo la temperatura ambiente. Los sensores fueron ubicados de acuerdo a criterio de experto en zonas térmicas que puedan dar un panorama térmico general de la máquina: carcasa, núcleo, devanado y roles.

En la tabla I se especifica el nombre de cada sensor y la ubicación en la máquina. En la figura 4 se muestra gráficamente la ubicación aproximada de cada uno de los sensores instalados.

Los sensores fueron debidamente calibrados y son de buena precisión, por lo que se supone que, además de la ubicación del sensor, no existe otro factor que influya de manera significativa sobre la variable respuesta (temperatura).

PERFORMANCE AT 230 V, 60 HZ, 2 HP			
Typical performance; not guaranteed values.			
General Characteristics			
Full Load Torque	0 LB-FT	Start Configuration	DOL
No-Load Current	0 A	Break-Down Torque	24.9 LB-FT
Line-Line Res. @ 25° C	2 Ohms A Ph / 0 Ohms B Ph	Pull-Up Torque	15.9 LB-FT
Temp. Rise @ Rated Load	65° C	Locked-Rotor Torque	17.2 LB-FT
Temp. Rise @ S.F. Load	77° C	Starting Current	47.8 A
Load Characteristics			
Rated Load	0% 25% 50% 75% 100% 125% 150% S.F.		
Power Factor	8.0 33.0 53.0 66.0 74.0 80.0 83.0 79.0		
Efficiency	0.0 75.5 84.1 86.4 86.5 85.9 84.6 86.2		
Speed (RPM)	1,799 1,790 1,779 1,769 1,756 1,743 1,728 1,748		
Line Amps	3.62 3.78 4.22 4.92 5.82 6.80 8.00 6.41		

Fig. 3. Datos de placa del motor en estudio.

Sensor	Ubicación	Nombre
S_1	Rol del Eje	RolEje
S_2	Rol del abanico	RolAbanico
S_3	Carcasa del lado del abanico	CarcasaAbanico
S_4	Carcasa centro	CarcasaCentro
S_5	Carcasa opuesto al abanico	CarcasaEje
S_6	Núcleo opuesto al abanico	Nucleo1
S_7	Núcleo del lado del abanico	Nucleo2
S_8	Devanado A	RTDA
S_9	Devanado B	RTDB
S_{10}	Devanado C	RTDC

TABLE I
SENSOR, NOMBRE Y UBICACIÓN EN LA MÁQUINA.




Fig. 4. Ubicación de los sensores instalados al motor.

IV. DISEÑO DEL EXPERIMENTO

Se realizaron seis pruebas al 100% de carga, completamente al azar durante las cuales se registró segundo a segundo y por un período de 2 horas 30 minuto las once mediciones de temperatura, esto generó 9.000 mediciones por cada sensor, para un total de 99.000 mediciones. Entre prueba y prueba se dispuso de un lapso de 3 horas para permitir que el motor se enfrié y alcance la temperatura ambiente. A partir de las mediciones se calculó la temperatura promedio para cada sensor, las cuales se muestran en el cuadro II. Así, por ejemplo, en la sexta prueba la temperatura promedio registrada por el sensor S_7 (Nucleo2) fue de 45.2°C.

V. ANÁLISIS DE VARIANZA

Se quiere evaluar la importancia del factor ubicación del sensor al comparar las medias de la variable respuesta temperatura en los diferentes niveles del factor (ubicaciones).

n	S_1	S_2	S_3	S_4	S_5	S_6	S_7	S_8	S_9	S_{10}
1	44.8	28.3	27.2	28.7	40.1	55.6	49.0	63.3	65.0	85.7
2	39.7	25.5	22.1	25.4	36.2	51.0	44.4	56.7	58.3	60.7
3	36.7	23.9	19.5	27.0	31.6	43.5	53.9	52.4	53.8	56.4
4	42.5	27.7	23.7	30.9	36.9	49.9	47.7	60.7	62.5	65.0
5	38.7	25.4	22.5	28.2	33.2	45.8	43.6	55.1	56.8	59.5
6	38.4	24.9	21.9	27.0	33.8	49.8	45.2	55.3	57.0	59.6

TABLE II
TEMPERATURA PROMEDIO REGISTRADA POR CADA SENSOR.

Para esto se aplicó la técnica ANOVA de un factor con la hipótesis nula de igualdad de medias para las temperaturas de los sensores y un nivel de significancia de $\alpha = 0.05$. Los resultados obtenidos se muestran en el cuadro VII de análisis de varianza.

Fuente	DF	Adj SS	Adj MS	Valor F^*	Valor p
Sensor	9	11110.6	1234.51	109.03	0
Error	50	566,1	11.23	11.32	
Total	59	11676.1			

TABLE III
ANOVA PARA LOS SENSOR.

Dado que $p = 0 < 0.05$, existen al menos dos sensores cuyas medias son diferentes. Los cuadrados medios reflejan que la diferencia debida a la ubicación del sensor es de 1234 y que el error es de 11.23, lo cual indica que las diferencias debidas a la ubicación de los sensores es significativa y que no se deben a pequeñas variaciones muestrales.

Para identificar en que grupos se han producido las diferencias se aplicó la prueba de comparación múltiple de Tukey con un 95% de confianza. Los resultados se muestran en el cuadro IV.

Sensor	Nombre	N	Media	Grupo
S_{10}	RTDC	6	61.42	A
S_9	RTDB	6	58.90	A
S_8	RTDA	6	57.25	A
S_6	Nucleo1	6	49.27	B
S_7	Nucleo2	6	47.28	B
S_1	RolEje	6	40.13	C
S_5	CarcasaEje	6	35.30	C
S_4	CarcasaCentro	6	27.87	D
S_2	RolAbanico	6	25.95	D
S_3	CarcasaAbanico	6	22.67	D

TABLE IV
COMPARACIÓN DE PARES DE MEDIAS POR SENSOR.

Observe que respecto a sus medias los sensores pueden ser agrupados en cuatro grupos: $A = \{S_8, S_9, S_{10}\}$, $B = \{S_6, S_7\}$, $C = \{S_1, S_5\}$ y $D = \{S_2, S_3, S_4\}$. Estos grupos definen cuatro zonas térmicas específicas de motor:

- Grupo A (Devanado): RTDA, RTDB y RTDC.
- Grupo B (Núcleo): Nucleo1 y Nucleo2.
- Grupo C (Frontal): RolEje y CarcasaEje.
- Grupo D (Abanico): CarcasaCentro, RolAbanico y CarcasaAbanico.

Observe que la zona más fría corresponde a la zona del abanico, lo cual es esperable debido a la cercanía del ventilador y la zona más caliente es el devanado.

En el cuadro V se muestra la media, desviación estándar e intervalos de confianza para cada uno de los sensores.

Sensor	N	Mean	StDev	95% CI
1	6	40,13	2,98	(37,37; 42,89)
2	6	25,950	1,697	(23,191; 28,709)
3	6	22,67	2,64	(19,91; 25,43)
4	6	27,867	1,876	(25,107; 30,626)
5	6	35,30	3,06	(32,54; 38,06)
6	6	49,27	4,22	(46,51; 52,03)
7	6	47,28	3,84	(44,52; 50,04)
8	6	57,25	4,02	(54,49; 60,01)
9	6	58,90	4,11	(56,14; 61,66)
10	6	61,42	4,00	(58,66; 64,18)

TABLE V
RESUMEN DE MEDIAS Y DESVIACIONES DE CADA SENSOR.

Por último, en el cuadro VI se resumen los porcentajes de error: R-cuadrado, R-cuadrado ajustado y R-cuadrado pronosticado del método, lo cual nos dice que el modelo explica un 94.28% de los datos.

S	R-sq	R-sq(adj)	R-sq(pred)
3.36494	95.15%	94.28%	93.02%

TABLE VI
PORCENTAJES DE ERROR ON ONCE SENSORES.

En la figura 5 se muestran los gráficos de probabilidad normal de los residuos, histograma de residuos, residuos versus ajuste y aleatoriedad de residuos, los cuales indican que los residuos se distribuyen normalmente, son aleatorios y no correlacionados.

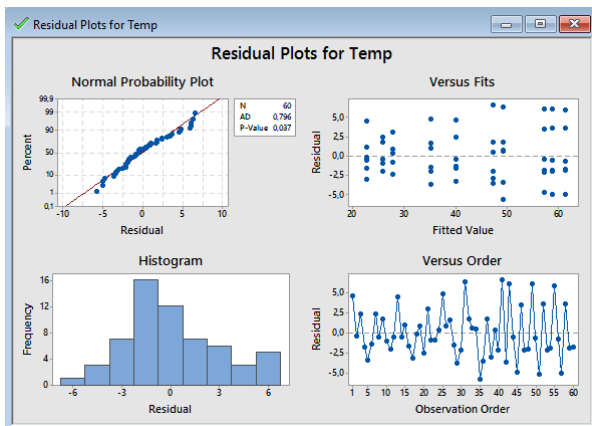


Fig. 5. Gráficos residuales.

VI. ESTIMACIÓN DE LA TEMPERATURA DEL ROTOR

Según el análisis ANOVA realizado la zona del abanico, grupo $D = \{S_2, S_3, S_4\}$, es la zona menos caliente de la máquina por lo que no se considero ninguno de estos sensores para la estimación de la temperatura del rotor. De las restantes

tres zonas se eligió un sensor por cada zona. Con el objetivo de aproximar la temperatura desde el exterior al interior de la máquina se eligió de la zona frontal (grupo C) el sensor S_5 y de la zonas núcleo (grupo B) y devanado (grupo A) se eligieron los sensores con mayor temperatura promedio, es decir, S_6 y S_{10} , respectivamente.

En resumen los sensores elegidos son:

Sensor	Nombre	Ubicación	Posición
S_5	CarcasaEje	Carcasa	$j = 0$
S_6	Nucleo1	Núcleo	$j = 1$
S_{10}	RTDC	Devanado	$j = 2$

Estas tres mediciones a lo largo del tiempo i y ubicación del sensor j definen una superficie que describe la temperatura en cada uno de estos puntos de medición, es decir,

$$T(i, j) \quad i = 1, 2, \dots, 9000 \quad j = 0, 1, 2$$

representa la temperatura en el i -ésimo segundo en la j -ésima posición. Así, $T(i, 0)$ representa la temperatura medida por el sensor CARCASA EJE en el i -ésimo segundo, $T(i, 1)$ representa la temperatura medida por el sensor NUCLEO1 en el i -ésimo segundo y $T(i, 2)$ representa la temperatura medida por el sensor RTDC en el i -ésimo segundo, con lo cual $T(i, 3)$ sería la temperatura estimada del rotor en el i -ésimo segundo.

Observe que podemos aproximar la temperatura del rotor mediante un desarrollo de Taylor de segundo orden para T

$$T(i, 3) = T(i, 2 + 1) = T(i, 2) + T'(i, 2) + \frac{1}{2}T''(i, 2) \quad (3)$$

Para aproximar cada una de las derivadas podemos usar las fórmulas de tres puntos

$$T'(i, 2) = \frac{1}{2}T(i, 0) - 2T(i, 1) + \frac{3}{2}T(i, 2)$$

$$T'(i, 0) = -\frac{3}{2}T(i, 0) + 2T(i, 1) - \frac{1}{2}T(i, 2)$$

$$T'(i, 1) = -\frac{1}{2}T(i, 0) + \frac{1}{2}T(i, 2)$$

Y para aproximar $T''(i, 2)$ podemos usar las fórmulas de tres puntos junto con las aproximaciones anteriores de T'

$$T''(i, 2) = \frac{1}{2}T'(i, 0) - 2T'(i, 1) + \frac{3}{2}T'(i, 2)$$

Finalmente, sustituyendo esto en la ecuación 3 obtenemos que la temperatura en el rotor puede estimarse por la ecuación:

$$T(i, 3) = T(i, 0) - 3T(i, 1) + 3T(i, 2) \quad (4)$$

Por ejemplo, si

$$\begin{aligned} T(9000, 0) &= 47.07 \\ T(9000, 1) &= 63.54 \\ T(9000, 2) &= 81.69 \end{aligned}$$

se tiene que la temperatura estimada del rotor es:

$$T(9000, 3) = 47.07 - 3 \cdot 63.54 + 3 \cdot 81.69 = 101.52$$

más la temperatura ambiente que en este instante es de 22.5 da un total de 124.02.

En la figura 6 se muestra la superficie que se obtuvo al aplicar la ecuación 4 a un nuevo conjunto de datos. Esta gráfica describe el aumento de la temperatura desde el exterior (carcasa) hasta el interior (rotor) en tiempo y profundidad.




Fig. 6. Temperatura estimada del rotor.

VII. VALIDACIÓN DE LA ESTIMACIÓN

Para validar la estimación de la temperatura del rotor dada por la ecuación 4 se realizó una nueva prueba y con estas nuevas mediciones de los sensores S_5 , S_6 , S_{10} y la ecuación 4 se generaron 9.000 aproximaciones correspondientes a la temperatura del rotor segundo a segundo. Además, mediante una pistola láser se realizaron mediciones de la temperatura del rotor cada 10 minutos como se muestran en el cuadro VII, donde se comparan con las correspondientes estimaciones de la temperatura del rotor.

Minuto	Pistola	Estimado
0	22.5	29.0
10	47.2	58.4
20	64.6	72.2
30	77.8	83.6
40	88.7	90.9
50	97.0	96.5
60	102.4	99.7
70	106.6	104.5
80	111.4	108.3
90	113.9	111.2
100	116.6	112.7
110	117.7	113.8
120	119.0	114.4
130	120.0	115.5
140	120.4	115.9

TABLE VII

TEMPERATURA DEL ROTOR MEDIDA (PISTOLA LÁSER) VERSUS ESTIMADA.

En la figura 7, se muestran las gráficas de la temperatura estimada del rotor, las mediciones hechas con la pistola láser y las mediciones de sensor RTDC.




Fig. 7. Temperatura: del rotor, pistola láser, estimada y RTDC.

VIII. CONCLUSIONES

El análisis ANOVA permitió agrupar los 10 sensores en cuatro grupos las cuales corresponden a zonas térmicas específicas del motor. Luego se eligió un sensor de cada una de estas zonas para construir una estimación de la temperatura interna de la máquina.

Dicha estimación fue valido usando las mediciones de una nueva prueba y comparándola con las mediciones obtenidas mediante una pistola láser.

REFERENCES

- [1] A. E. Emanuel, "A quantitative approach to estimate the life expectancy of motor insulation systems," *IEEE Transactions on Dielectrics and Electrical Insulation*, vol. 9, pp. 627–628, Aug 2002.
- [2] P. Pillay and M. Manyage, "Loss of life in induction machines operating with unbalanced supplies," *IEEE Transactions on Energy Conversion*, vol. 21, pp. 813–822, Dec 2006.
- [3] J. F. Moreno, F. P. Hidalgo, and M. D. Martinez, "Realisation of tests to determine the parameters of the thermal model of an induction machine," *IEE Proceedings - Electric Power Applications*, vol. 148, pp. 393–397, Sep 2001.
- [4] M. J. Duran and J. Fernandez, "Lumped-parameter thermal model for induction machines," *IEEE Transactions on Energy Conversion*, vol. 19, pp. 791–792, Dec 2004.
- [5] O. I. Okoro, B. Weidemann, and O. Ojo, "An efficient thermal model for induction machines," in *Industry Applications Conference, 2004. 39th IAS Annual Meeting. Conference Record of the 2004 IEEE*, vol. 4, pp. 2477–2484 vol.4, Oct 2004.
- [6] Z. Gao, T. G. Habetler, R. G. Harley, and R. S. Colby, "An adaptive kalman filtering approach to induction machine stator winding temperature estimation based on a hybrid thermal model," in *Fourtieth IAS Annual Meeting. Conference Record of the 2005 Industry Applications Conference, 2005.*, vol. 1, pp. 2–9 Vol. 1, Oct 2005.
- [7] A. Boglietti, A. Cavagnino, and D. Staton, "Determination of critical parameters in electrical machine thermal models," *IEEE Transactions on Industry Applications*, vol. 44, pp. 1150–1159, July 2008.
- [8] B. Dutta and S. K. Chowdhury, "Steady state thermal model of tefc induction machine," in *2012 IEEE International Conference on Power Electronics, Drives and Energy Systems (PEDES)*, pp. 1–6, Dec 2012.
- [9] L. Murillo-Soto, G. Figueroa-Mata, and O. Guerrero-Castro, "Identificación de parámetros de un modelo térmico para un motor trifásico de inducción usando algoritmos genéticos," *Revista Tecnología en Marcha*, vol. 29, no. 5, pp. 25–41, 2016.

- [10] L. Murillo-Soto, "Aplicación informática para el monitoreo de variables eléctricas , mecánicas y térmicas en motores trifásicos de inducción," in *Proceedings of the Twelfth Latin American and Caribbean Conference for Engineering and Technology* (M. M. L. Petrie, H. Alvarez, and C. R. Arroyave, eds.), July 2014.

MODELO TÉRMICO PROPUESTO PARA MOTORES TRIFÁSICOS

Luis D. Murillo-Soto, Magister en Computación,
Tecnológico de Costa Rica, Costa Rica, lmurillo@itcr.ac.cr

Resumen: En este apéndice se presenta el modelo térmico para motores eléctricos, que se usará para como referencia base para calcular el vector de error con los datos medidos

El modelo general para motores eléctricos se propone en la tesis doctoral de G. Kylander [1] y se resume en la ecuación (1).

$$\mathbf{C} \frac{d\mathbf{T}}{dt} = \mathbf{P} - \mathbf{GT} \quad (1)$$

Donde \mathbf{C} es la matriz de conductancias térmicas, \mathbf{T} es el vector de temperaturas del respectivo nodo, \mathbf{P} es el vector de las pérdidas del motor y \mathbf{G} es la matriz de conductancias térmicas.

A partir del estudio y análisis de distintas topologías propuestas en la literatura [1], [2], [3], [4], [5], [6] se propone la propia, a partir de la representatividad de las fallas que se desea detectar. La ecuación (1) vista desde el punto de vista nodal se muestra en (2)

$$C_i \frac{dT_i}{dt} = P_i - \sum_{j=1}^n G_{ij}(T_i - T_j) \quad (2)$$

Donde el subíndice i representa la ecuación del nodo respectivo y el subíndice j son otros elementos con los que hay una conexión mediante una conductancia y temperatura. De esta forma se propone ocho puntos de medición los cuales se representan como $\{ T_1, T_2, T_3, T_4, T_5, T_6, T_7, T_8 \}$.

La expansión de cada término de la ecuación (2) queda de la forma siguiente:

$$\mathbf{C} \frac{d\mathbf{T}}{dt} = \begin{pmatrix} 0 \\ 0 \\ 0 \\ C_N \frac{dT_4}{dt} \\ C_{Cu} \frac{dT_5}{dt} \\ 0 \\ 0 \\ C_R \frac{dT_8}{dt} \end{pmatrix}$$

$$P = \begin{pmatrix} 0 \\ 0 \\ 0 \\ P_N \\ P_{Cu} \\ P_F \\ 0 \\ P_R \end{pmatrix}$$

$$G = \begin{pmatrix} G_{CA1} + G_{NC1} + G_{ReC} & 0 & 0 & -G_{NC1} & 0 & -G_{ReC} & 0 & 0 \\ 0 & G_{CA2} + G_{NC2} & 0 & -G_{NC2} & 0 & 0 & 0 & 0 \\ 0 & 0 & G_{CA3} + G_{NC3} + G_{CRa} & -G_{NC3} & 0 & 0 & -G_{CRa} & 0 \\ -G_{NC1} & -G_{NC2} & -G_{NC3} & G_{CN} + G_{NC1} + G_{NC2} + G_{NC3} & -G_{CN} & 0 & 0 & 0 \\ 0 & 0 & 0 & -G_{CuN} & G_{CuN} + G_{Eh} & 0 & 0 & -G_{Eh} \\ -G_{ReC} & 0 & 0 & 0 & 0 & G_{ReC} + G_{RRe} & 0 & -G_{RRe} \\ 0 & 0 & -G_{CRa} & 0 & 0 & 0 & G_{CRa} + G_{RRa} & -G_{RRa} \\ 0 & 0 & 0 & 0 & -G_{Eh} & -G_{RRe} & -G_{RRa} & G_{Eh} + G_{RRe} + G_{RRa} + G_{RA} \end{pmatrix}$$

$$T = \begin{pmatrix} T_1 \\ T_2 \\ T_3 \\ T_4 \\ T_5 \\ T_6 \\ T_7 \\ T_8 \end{pmatrix}$$

La figura 1 y 2 muestra las representación gráfica del modelo propuesto.




Fig 1. Modelo térmico del motor eléctrico.

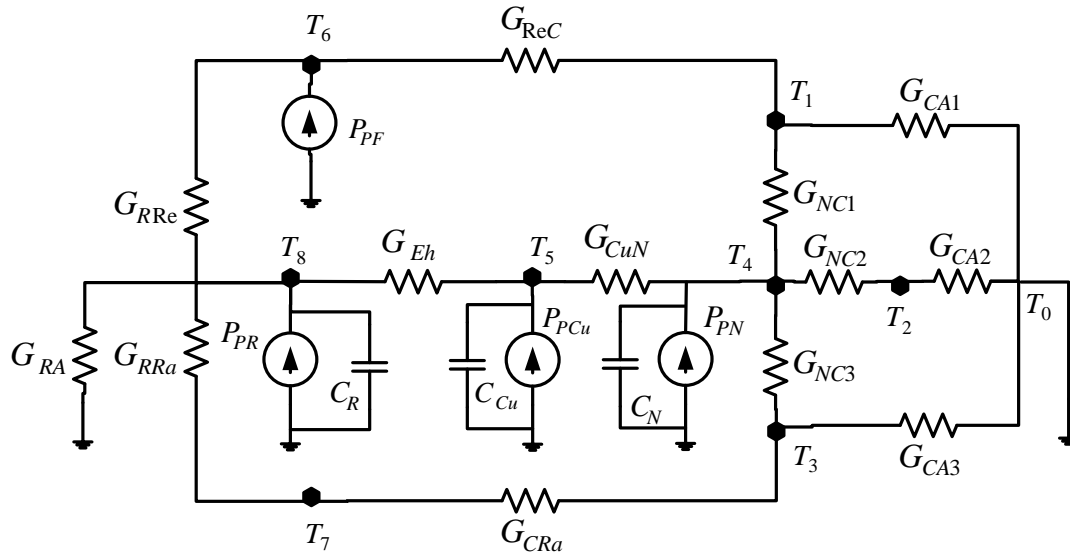


Fig 2. Representación del modelo térmico para análisis.

Referencias.

- [1] G. Kylander, "Thermal modelling of small cage induction motors," Chalmers University of Technology, 1995.
- [2] I. Boldea and S. A. Nasar, *The Induction Machine Handbook*. CRC Press, 2002.
- [3] P. Pillay and M. Manyage, "Loss of life in induction machines operating with unbalanced supplies," *IEEE Trans. Energy Convers.*, vol. 21, no. 4, pp. 813–822, 2006.
- [4] M. J. Duran and J. Fernandez, "Lumped-Parameter Thermal Model for Induction Machines," *IEEE Transactions on Energy Conversion*, vol. 19, pp. 791–792, 2004.
- [5] K. Feldmann, A. W. Colombo, C. Schnur, and T. Stockel, "Specification, design, and implementation of logic controllers based on colored Petri net models and the standard IEC 1131. II. Design and implementation," *IEEE Trans. Control Syst. Technol.*, vol. 7, no. 6, pp. 666–674, 1999.
- [6] J. F. Moreno, F. P. Hidalgo, and M. D. Martínez, "Realisation of tests to determine the parameters of the thermal model of an induction machine," *IEE Proceedings - Electric Power Applications*, vol. 148, p. 393, 2001.

Modelado de señales de temperatura usando redes neuronales para la generación de residuos

Jefferson González-Gomez¹, Luis D. Murillo-Soto²

Instituto Tecnológico de Costa Rica

Cartago, Costa Rica, { jefg89@gmail.com¹, lmurillo@itcr.ac.cr² }

Resumen:

El principal inconveniente para desarrollar sistemas de detección de faltas de sistemas complejos, es la obtención confiable del modelo dinámico del sistema. La elaboración analítica de un sistema complejo, muchas veces no es factible dado que se desconoce muchas veces las dinámicas por lo que no es factible realizar la identificación del sistema. En este sentido los métodos basados en redes neuronales permiten obtener un modelo sin necesidad de conocer en detalle el comportamiento dinámico del objeto en estudio. En este trabajo se muestra la implementación en LabVIEW 12.0 de una red neural multicapa y su algoritmo de entrenamiento, utilizados para identificar curvas de temperatura de un motor eléctrico.

III. INTRODUCCIÓN.

Las técnicas para detectar faltas en sistemas continuos se dividen básicamente en dos grandes subconjuntos; unas basadas en modelos de señales y otras basadas en modelos. Las basadas en señales, estudian el comportamiento de la señal y buscan valores fuera de rangos definidos, cambios abruptos en sus derivadas o tendencias, patrones específicos de las señales a partir de técnicas de análisis espectrales, correlaciones, wavelets, etc., existen una amplia variedad de técnicas definidas en (Isermann, 2006) ver figura 1a. Por otra parte, las técnicas de detección basadas en modelos, utilizan los datos generados a partir del modelo dinámico del sistema sin faltas y se confrontan con las señales reales para generar residuos. El residuo es sinónimo de error, es la diferencia entre un valor real y el valor brindado por el modelo. En la figura 1b se observa el esquema usando modelos del sistema o proceso.

El proyecto SEMAT, que actualmente se desarrolla en el Instituto Tecnológico de Costa Rica, busca un sistema en línea para la detección y posteriormente diagnóstico de faltas térmicas en motores de inducción. Dicho proyecto adoptó el esquema de diseño por modelos. De las técnicas existentes para construir modelos, se decidió por utilizar redes neuronales, dado que para el

modelaje se carecen de los datos de necesarios para construir el modelo térmico del motor, por lo que se optó por la construcción del modelo a partir de una red neuronal.

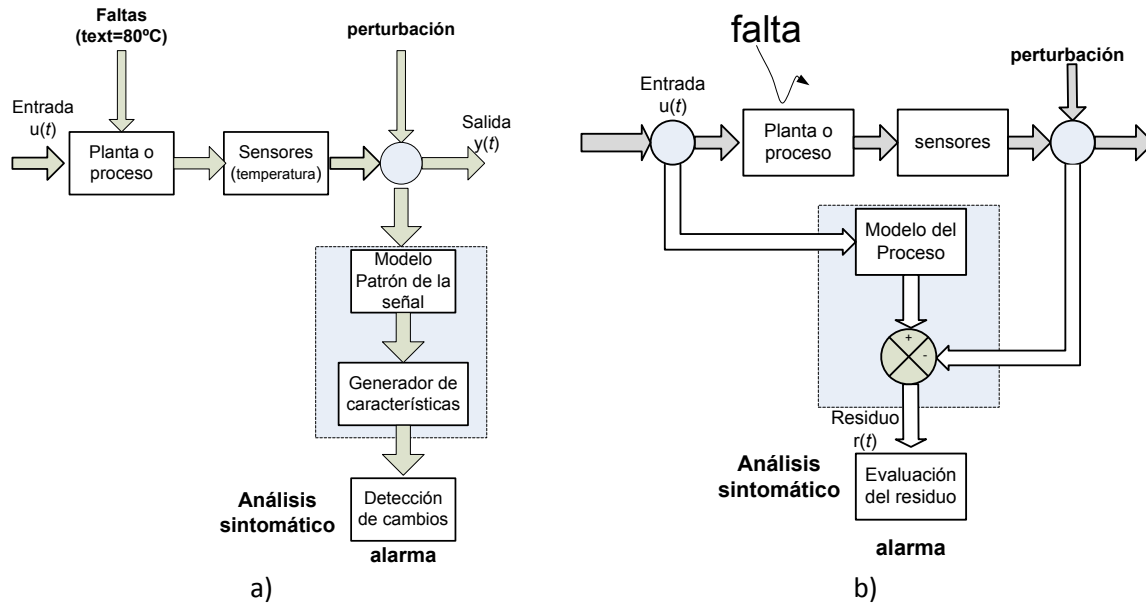


Figura 1. a) Detección de faltas usando análisis de la señal. b) Detección de faltas usando modelo del sistema.

El presente trabajo está dividido en las siguientes secciones, 2) teoría de la red neuronal artificial, y algoritmo de entrenamiento, 3) Implementación de la red en LabVIEW, 4) Resultados preliminares de la red construida.

IV. TEORÍA DE LA RED NEURONAL ARTIFICIAL

Una red neuronal artificial es un modelo simplificado del sistema neuronal humano (Reby, Lek, & Dimopoulos, 1997). La unidad más simple de una red es llamada *neurona*. La figura 2 muestra un modelo de una neurona artificial




Figura 2. Modelo de neurona artificial [2]

La salida para una neurona simple, como la mostrada arriba, puede ser obtenida como una función de la suma de cada una de sus entradas (x_i) multiplicada por un factor de peso (W_{ji}). Adicionalmente se agrega a esta función, un valor de polarización (b – bias). El factor F , suele ser una función o una constante, para el caso de una neurona lineal, F (también llamada función de activación) equivale a 1, de esta forma la función de salida para la neurona lineal simple viene dada por:

$$y = \sum_{i=1}^N x_i W_{ji} + b \quad (1)$$

De hecho, para muchas aplicaciones, es común que las capas ocultas no tengan una función de activación lineal, esto debido a que es deseable que la red puede reproducir y “aprender” comportamientos no lineales. Para esto, la función de activación de capa oculta más utilizada es la conocida función *sigmoidal*:

$$F(out) = \frac{1}{1 + e^{-out}} \quad (2)$$

Bajo esta configuración para cada neurona (independientemente de su función de activación), una red neuronal artificial consiste en un cierto número de neuronas distribuidas en **3** (caso más común) o más capas: una capa de entrada, una (o más) capas ocultas y una capa de salida. En la Figura 3 se muestra una configuración de red con 3 capas.




Figura 3. Arquitectura de una red neuronal con una capa oculta

B. *Algoritmo de retropropagación (González, Arias, & Carvajal, 2014) (Reyes & Antonio, 2007)*

Una vez seleccionada la arquitectura de la red neuronal, es necesario entrenar la red, a fin de ajustar los valores de los pesos entre las capas, este ajuste de pesos es finalmente el causante de que la red puede “aprender” el comportamiento deseado para su salida.

Una de las técnicas más comunes de entrenamiento (supervisado) de redes neuronales la retropropagación (BP por sus siglas en inglés). La retropropagación es una técnica en la que la red es entrenada con un conjunto de entradas y valores esperados de la salida, para cada una de sus entradas. En cada iteración del algoritmo, los pesos son auto ajustados, con el fin de minimizar el error entre la salida actual de la red y su valor esperado. Este ajuste se aplica desde las capas de salida hasta las capas de entrada, de ahí el nombre de retro propagación. Para cada neurona en la capa de salida, el ajuste de los pesos (W_{kj}) se puede obtener como:

$$W_{kj}(k + 1) = \eta \delta_{pk} y_{pj} + W_{kj}(k) \quad (3)$$

Donde η es la velocidad de aprendizaje, δ_{pk} para una red lineal, es la diferencia entre el valor esperado y la salida actual, y y_{pj} corresponde a la salida de j-esima neurona oculta.

Para el caso de los pesos de la capa oculta, para calcular el valor de delta (δ_{pj}), se necesita antes el valor delta de la capa de salida (δ_{pk}) junto con su vector de pesos:

$$\delta_{pj} = y_{pj}(1 - y_{pj}) \sum_k \delta_{pk} W_{kj} \quad (4)$$

Donde el término que precede a la suma surge del comportamiento derivativo (error) de la función de activación sigmoideal, correspondiente a las neuronas de la capa oculta. El ajuste final de los pesos de la capa oculta sigue el procedimiento descrito anteriormente para la capa de salida, con la leve modificación de que se incluye en este caso cada una de las entradas de la red (xi):

$$W_{ji}(k + 1) = \eta \delta_{pj} x_i + W_{ji}(k) \quad (5)$$

V. IMPLEMENTACIÓN DE UNA RED NEURONAL ARTIFICIAL EN LABVIEW

Las siguientes figuras muestran la implementación de una red neuronal general (X entradas, N neuronas de capa oculta, Y salidas)

En la figura 4, en azul, se denota la capa de entrada, que básicamente representa el vector con cada una de las entradas a la red.

En **rojo** se muestra la implementación de la capa oculta. Las entradas de esta capa corresponden a las entradas generales de la red (provenientes de la capa de entrada) así como el vector bidimensional de pesos de capa oculta (W_{ji}) : para cada neurona en la capa oculta, para cada entrada de la red. La función de activación seleccionada, como se mencionó anteriormente, corresponde a la *sigmoidal* y su implementación se realiza por medio de un SubVI. El vector de salidas de la capa oculta es la señal Y_{pj} .

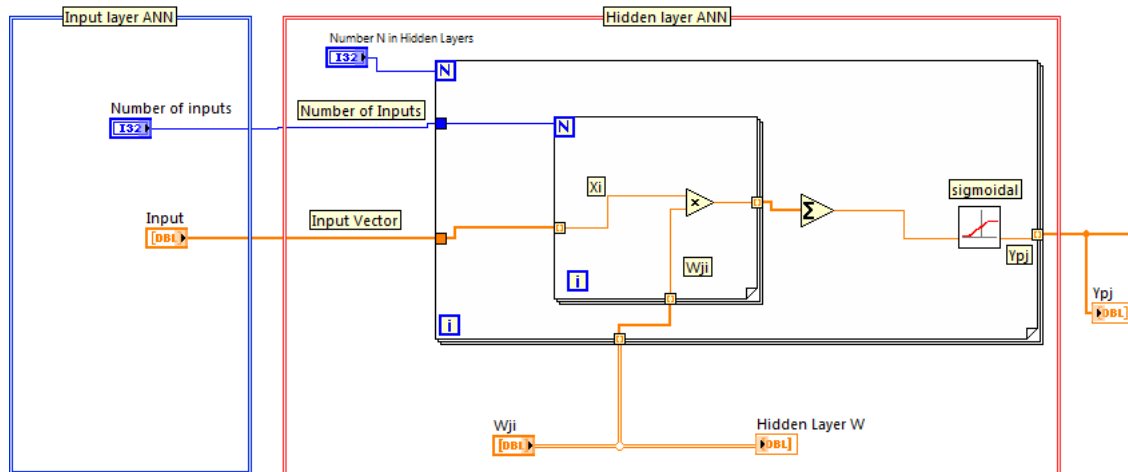


Figura 4. Implementación en LabVIEW de las capa de entrada (azul) y oculta (roja) de la red neuronal.

La implementación de la capa de salida se muestra en la Figura 5., para esta capa se seleccionaron neuronas lineales, como las descritas anteriormente. La implementación permite definir cualquier número de salidas. La entrada de esta capa es el vector de salida de la capa oculta Y_{pj} , junto con el vector de pesos (W_{kj}).

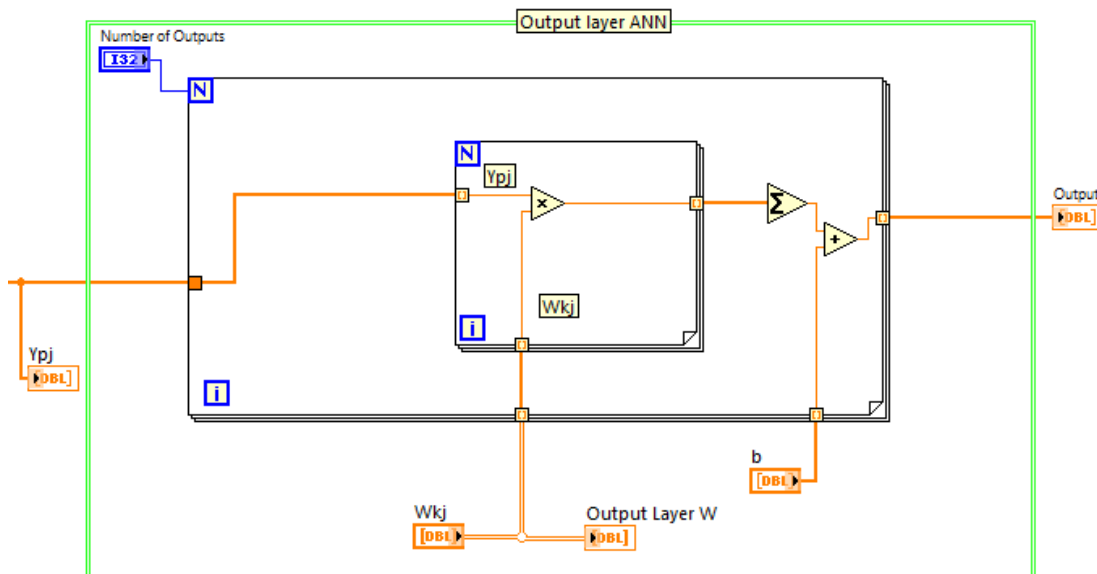


Figura 5. Implementación en LabVIEW de la capa de salida de la red neuronal.

A. *Implementación del algoritmo de retropropagación en LabVIEW*

La red neuronal entonces se implementó completa en un SubVI, de modo de que exista la posibilidad de reutilizar esta red y a su vez utilizarla en el algoritmo de retropropagación. De tal forma que el algoritmo instancia el SubVI y genera la salida de la red en cada una de las iteraciones. El número de iteraciones, número de neuronas en capa oculta, número de entradas, número de salidas, vector de entradas y vector de salidas esperadas, son las entradas del método entrenamiento por retropropagación. Las salidas del método implementado corresponden a los vectores con los pesos de las capas de salida y oculta respectivamente.

B. *Descripción del algoritmo implementado*

La parte inicial del algoritmo es la generación inicial de los pesos, esto es para que la red pueda generar los primeros valores de salida. Existen múltiples métodos de generación de pesos, pero se eligió para esta implementación, la generación de números aleatorios entre 0 y 1 para cada vector de pesos.

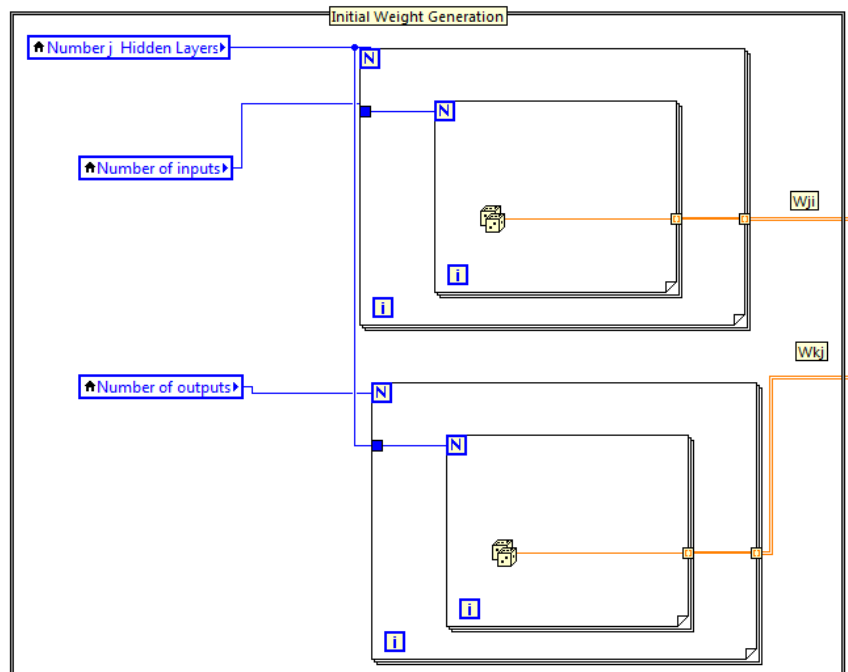


Figura 6. Generación inicial aleatoria de los vectores de pesos de las capas.

Una vez generados los pesos iniciales, se procede al ajuste de los pesos de la capa oculta. La ecuación de ajuste Ec. (2) se implementó en LabVIEW de la siguiente manera:

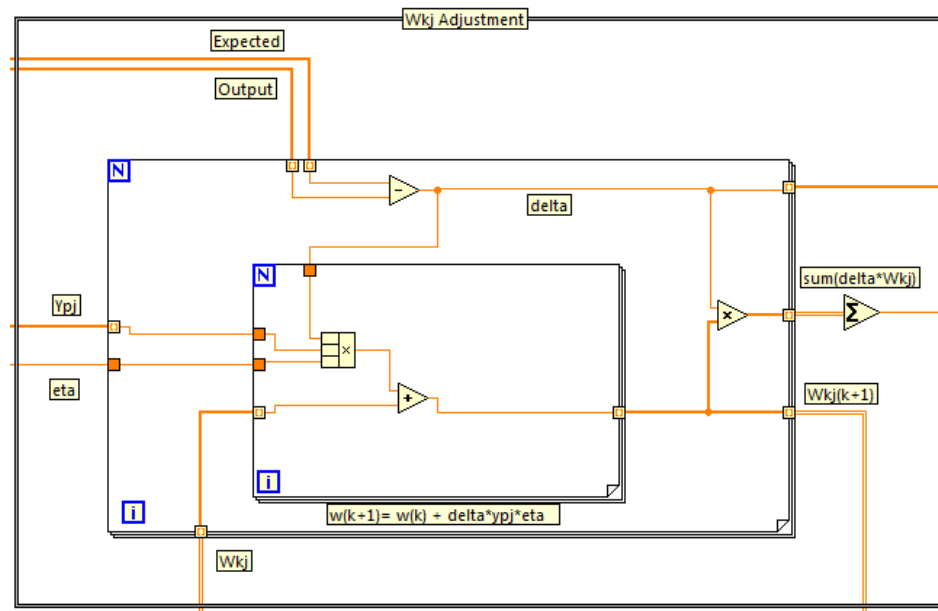


Figura 7. Implementación en LabVIEW del ajuste de pesos para la capa de salida

Este módulo se encarga de calcular el nuevo valor de los pesos de la capa de salida ($W_{kj}(k+1)$) según la ecuación (3), además de generar la señal de la suma del delta de cada salida multiplicada por los pesos, esta última señal corresponde al segundo término de la ecuación (4).

El segundo paso es el ajuste de los pesos de las neuronas de la capa oculta, esto se implementó (Figura 8) con base en las ecuaciones (4) y (5).

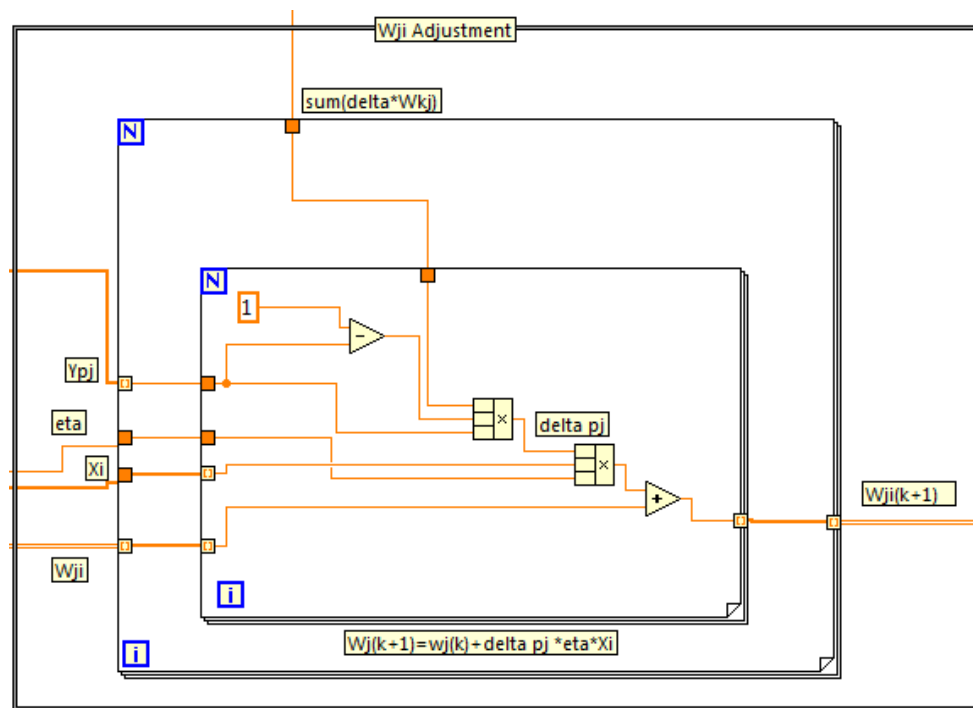


Figura 8. Implementación en LabVIEW del ajuste de pesos para la capa oculta

VI. RESULTADOS PRELIMINARES

A. El problema de la XOR:

Como parte de las pruebas de entrenamiento, se decidió abordar el problema de XOR comúnmente conocido en el área de las redes neuronales artificiales. El problema, básicamente, consiste en la incapacidad de una red (lineal o no) de dos capas de reproducir el comportamiento de una función lógica XOR, eso debe a las limitaciones matemáticas y lógicas producto de las funciones de las redes.

Como en este caso, se trata de una red de 3 capas, se reprodujo el problema con el fin de observar el comportamiento de la red implementada, junto con el algoritmo de retropropagación, ante este problema y de esta forma verificar el correcto funcionamiento de la misma.

La figura 9 demuestra los parámetros de entrada del algoritmo:

	Input		Expected	
Number of inputs	0		0	
2	1	1	0	
Number j Hidden Layers	1	1	0	
50	1	0	1	
Number of outputs	1	0	1	
1	1	1	0	
0	0	0	0	
0	1	1	0	
-1.5	0	1	1	
eta	1	1	0	
0.02	0	0	0	
Number of iterations	1	1	0	
100	0	0	0	
	1	1	0	
	1	1	0	

Figura 9. Parámetros de entrada del método de retropropagación implementando la función XOR

La respuesta de la red, así como los vectores de peso de ambas capas de muestran la figura 10.

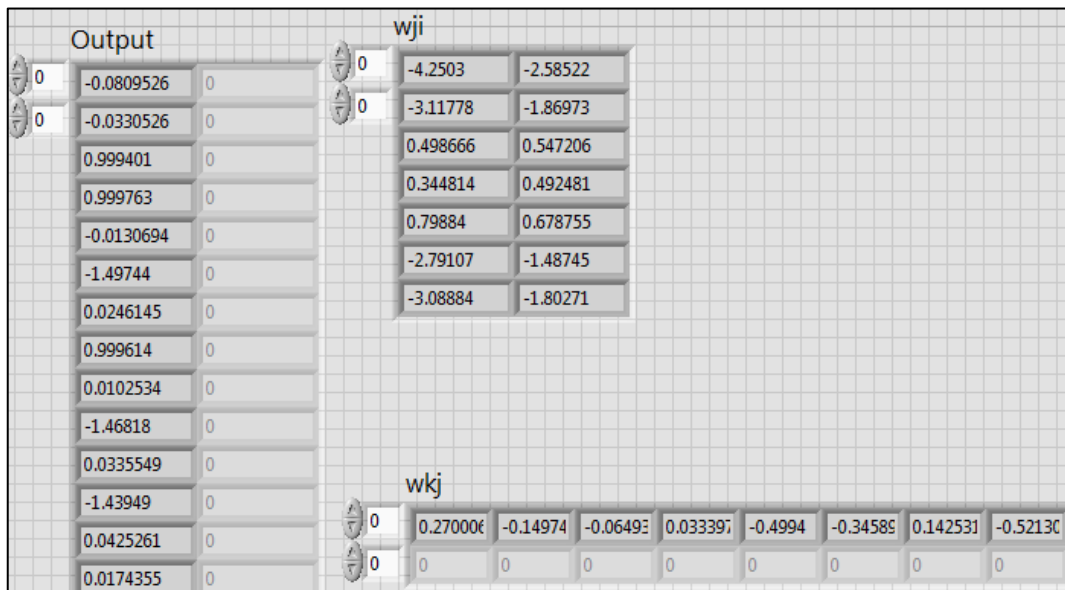


Figura 10. Parámetros de salida del método de retropropagación implementando la función XOR

La síntesis del funcionamiento de la red ante el problema de la XOR se muestra en la Tabla 1.

De la tabla se puede apreciar cómo, en los casos en que la función da “1”, la red calcula un valor positivo muy cercano a 1 (0.99), y en los casos de que es “0”, dependiendo de las entradas, puede ser un valor negativo o muy cercano a 0 que puede ser fácilmente clasificado como un 0, lo que corresponde con la función.

Tabla 1. Funcionamiento de la red ante el problema de la XOR

Entradas		Salida esperada	Salida de la red
1	1	0	-0.0809526
1	1	0	-0.0330526
0	1	1	0.999401
1	0	1	0.999763
0	0	0	-0.0130694
0	0	0	-1.49744
1	1	0	0.0246145
1	0	1	0.999614
1	1	0	0.0102534
0	0	0	-1.46818
1	1	0	0.0335549
0	0	0	-1.43949
1	1	0	0.0425261
1	1	0	0.0174355

B. *Identificación experimental (seguimiento) de una señal de temperature*

Otra de las pruebas realizadas fue la de la identificación (seguimiento, predicción) del comportamiento de una señal de temperatura real, producto del calentamiento natural, de un motor de 5HP. Para esto se utilizó un conjunto con 6000 datos de temperatura, de los cuales, un 60% se utilizaron para entrenar y la totalidad de los datos para verificar.

El sistema lee los valores de un archivo ASCII (.txt) y se encarga de distribuir las muestras en entrenamiento y verificación. Los parámetros de entrada utilizados fueron: 100 iteraciones, b (offset) =24 °C, 12 neuronas de capa oculta. El resultado de este experimento se muestra en la Figura 11. El error promedio entre el dato real y el calculado por la red corresponde a un 3.78%, tomando en cuenta además el entrenamiento.

Los vectores generados de peso de la capa oculta y capa de salida (Figura 12) permiten reproducir la función, si necesidad repetir el entrenamiento y obtener el mismo resultado.




Figura 11. Resultado de la identificación de la señal de temperatura de un motor de 10 HP




Figura 12. Vectores de pesos para las capas oculta y de salida

VII. REFERENCIAS

- González, J., Arias, Y., & Carvajal, Y. (2014). Online Bridge Vibration Analysis and Intelligent fault detection approach using FFT-ANN on an embedded system. Liberia: IWOB.
- Isermann, R. (2006). *Fault Diagnosis Systems*. Berlin: Springer-Verlag.
- Reby, D., Lek, S., & Dimopoulos, I. (1997). Artificial neural networks as classification method in the behavioural sciences. *Behavioural Processes*, 40(1), 35-43.
- Reyes, V., & Antonio, M. (2007). *Algoritmo backpropagation para redes neuronales: conceptos y aplicaciones*. Instituto Politécnico Nacional. Centro de Investigaciones en Computación.

Pesos de la RNA “feed-forward” implementada

MATRIZ W1

```
[-1.2423 2.1912 0.073038 0.96345 1.066 -0.74207 0.56533 -1.0924 -0.87794 1.111;  
4.053 3.3724 -2.2255 1.4963 -1.0331 -5.0653 -2.8597 -4.1695 9.5381 4.4744;  
-0.33434 -0.30793 -1.3157 1.0503 2.0149 -1.6546 0.55831 0.47035 0.62772 -0.583;  
-4.2423 -2.65 2.8389 0.73411 0.14982 2.6368 0.18383 2.6148 -3.7894 -4.4152;  
1.7845 1.3036 -0.082117 -4.4381 -0.51384 1.371 -1.5788 0.039037 3.9254 7.4026;  
-0.43973 -0.01152 -1.0128 -0.36973 -0.86918 -0.0073139 -0.77604 -0.45672 -0.37524 0.46459;  
-0.052836 0.72432 -1.1521 0.52827 0.71102 0.87852 0.2667 0.28066 0.95071 0.5043;  
-0.16377 -0.43805 0.46477 1.5158 -1.0366 -0.075048 -1.1018 -0.70154 -0.50434 -0.62567;  
0.69889 0.69118 0.25046 0.18716 0.57129 0.23258 0.65641 0.7294 0.86667 0.46545;  
-1.6078 -0.57192 1.9422 5.0292 0.63627 -1.7851 0.59278 0.90016 -1.8857 -2.4431]
```

MATRIZ W2

```
[-1.2285 -1.2053 -0.029652 -2.8761 2.6464 1.2156 -0.50035 0.69432 -1.0355 -2.8863;  
2.7173 6.185 0.6833 10.1227 5.7175 1.7605 -3.3074 3.1069 -0.47679 -1.5313;  
-0.2927 -3.6666 2.2795 -1.6325 -2.9147 0.19654 0.40479 0.20525 -0.54666 3.6477;  
-3.3334 8.6764 2.7386 -1.6146 2.081 1.2916 -0.31942 0.96417 -2.3817 2.2378]
```

VECTOR B1

```
[1.3977;  
0.34892;  
-0.50633;  
0.20854;  
-0.97781;  
-0.29396;  
-0.97455;  
-1.1356;  
1.3647;  
-1.7637]
```

VECTOR B2

```
[0.95658;  
-2.4307;  
-0.84134;  
-3.6264]
```

Scout-Augmented Artificial Bee Colony Algorithm

Luis Ernesto Carrera

Geovanni Figueroa

Osvaldo Guerrero

Luis Diego Murillo

22 de abril de 2015

1. Idea del algoritmo

Basado en el algoritmo *Global-best guided Artificial Bee Colony* (GbABC), la idea del presente algoritmo es dar mayor importancia a la fase de búsqueda (scout bees step). Para ello se cambia el proceso de búsqueda, el proceso de recolección, y se elimina el proceso de “ojear” (onlookers bees step).

El objetivo es resolver problemas de optimización continua, en un hipercubo.

Inicialmente se generan puntos aleatorios sobre el hipercubo. A partir de ahí, cada abeja trabaja independientemente. Cada una tiene dos estados. Uno es el estado de *employee* o *recolectora*, en donde se encarga de *recolectar* información alrededor del punto donde se encuentra, y guardando siempre su óptimo local; si realizan una cantidad dada de intentos en los que no encuentran un mejor punto, entonces cambian al estado de *buscadoras* (llamadas también *scouts*).

El inicio de la ruta para las abejas buscadoras se elige de manera aleatoria en una de las caras del hipercubo, luego escogen dos direcciones de desplazamiento: la primera es su óptimo local respectivo, y la otra se escoge mediante una ruleta, con respecto al valor de las funciones de aptitud de todos los óptimos locales.

En ambos estados, la velocidad del vuelo de la abeja depende de la aptitud del lugar en el que se encuentra, y el desplazamiento se basa en *simulated annealing*.

2. Ejecución del algoritmo

1. Construir la estructura principal `sabc_info`:

```
<info> = sabc_info_alloc(<n>, <f>, <fparams>)
```

2. Modificar aquellos parámetros que se consideren convenientes. Probablemente se deben modificar al menos las coordenadas de las dimensiones `sabc_info::dmin` y `sabc_info::dmax`. La lista de parámetros se detalla más adelante.
3. Crear la estructura temporal del problema.

```
<algthm> = sabc_algthm_alloc(<info>)
```

- Definir los puntos iniciales de búsqueda en `sabc_info::best_pos`. Se pueden definir manualmente, o si se quieren que sean aleatorios se puede utilizar la función ya implementada:

```
sabc_rand_start_points(<info>, <alghthm>);
```

Por ahora es posible reiniciar el algoritmo si no se modifican los parámetros.

3. Estructura del problema

Se tiene una función $f : \mathbb{D}^n \rightarrow \mathbb{R}$, donde \mathbb{D} es un hipercubo para el cual se conocen d_i^{\min} y d_i^{\max} , $i = 1 \dots n$, que corresponden al mínimo y máximo respectivamente, en cada una de las dimensiones. El problema requiere los siguientes parámetros:

- `sabc_info::bn`: El número de abejas buscadoras/recolectoras. Default: `bn = 15`. Sugerido: `bn ∈ {5, ..., 100}`.

Racional: A mayor número debería aumentar la probabilidad de encontrar una buena solución, aunque al costo de aumentar el tiempo de duración del algoritmo.

- `sabc_info::lf`: Parámetro real utilizado para determinar la capacidad recolectora de las abejas cosechadoras. El número máximo de veces que cosechan sin mejorar la solución actual está dada por `limit = ⌈lf · n⌉`, donde n es la dimensión del hipercubo. El valor por default es `lf = 10.0`, el rango sugerido es `lf ∈ [2.0, 20.0]`.

Racional: A mayor valor, cada abeja busca más alrededor del punto; podría aumentar la probabilidad de encontrar algo, a costa de mayor tiempo de duración del algoritmo.

- `sabc_info::ssratio`: Unidad de distancia, como porcentaje del tamaño de cada arista. El tamaño máximo posible para un paso es una unidad. Default: `ssratio = 0.10` (10%). Sugerido: `ssratio ∈ [0.02, 0.20]`.

Racional: Un tamaño mayor aumenta el rango de trabajo de las cosechadoras y de las buscadoras, pero al aumentar el tamaño del paso, podría pasar por encima de algún óptimo.

- `sabc_info::alpha` y `sabc_info::beta`: Parámetros para la función de aptitud. $\alpha = 10.0$, rango sugerido $\alpha ∈ (0.0, 50.0)$; $\beta = 1.1$, rango sugerido $\beta ∈ (1.0, 1.5)$. (El parámetro α tal vez pueda ser modificado “en línea” haciendo un análisis de la desviación estándar, mientras que para el parámetro β , sirve cualquier valor mayor que 1.0).

Racional: Ver Sección 4.

4. Función de aptitud

La función de aptitud se utiliza tanto para la etapa de búsqueda como para la etapa de cosecha, y está dada por:

$$\text{fitness}(\mathbf{x}) = \frac{\alpha}{f(\mathbf{x}) - f^* + \alpha \cdot \beta}$$

donde, f^* es el mejor valor encontrado hasta el momento, α y β son parámetros, donde por default $\alpha = 10.0$ y $\beta = 1.1$.

Si el valor de $f(\mathbf{x}) \gg f^*$, entonces $\text{fitness}(\mathbf{x}) \rightarrow 0$; es decir, valores positivos cercanos a 0 implican que el punto es “malo” (la abeja se alejará de él más rápido). Conforme $f(\mathbf{x}) \rightarrow (f^*)^+$ entonces $\text{fitness}(\mathbf{x}) \rightarrow 1/\beta$. Si se diera el caso en que $f(\mathbf{x}) < f^*$, entonces $f^* \leftarrow f(\mathbf{x})$. Es decir, $\text{fitness}(\mathbf{x}) \in (0, 1/\beta]$.

El valor de α determina que tan cercano al punto óptimo debe encontrarse un punto para considerarse “bueno” o “malo”: valores cercanos a 0 deberían utilizarse para funciones con pocas variaciones, pues tienden a hacer los desplazamientos más pequeños; mientras que valores grandes hacen las búsquedas más amplias.

Por otro lado el valor de $1/\beta$ corresponde al valor de aptitud del punto óptimo. Dicho valor debe ser menor que 1, ya que $1.0 - 1.0/\beta$ es la velocidad de la abeja buscadora en el punto óptimo (en términos de @c ss), por lo que se recomienda que $\beta \in (1.0, 1.5)$, aunque ciertamente cualquier valor mayor que 1 funciona.

5. Desplazamiento

En cualquiera de los dos estados, la abeja se encuentra en algún punto dado, y se escogerán dos dimensiones en las cuales realizará su movimiento.

Dado un valor aleatorio $s \in [0, 1)$, entonces se determina el parámetro:

$$t = \frac{1 - \text{fitness}(\mathbf{x})}{\sqrt{s^2 + (1 - s)^2}}$$

El cambio en la primera de las dimensiones está dado por st , mientras que en la segunda dimensión por $(1 - s)t$.

Sea $\hat{\mathbf{x}}$ el nuevo punto calculado. Si $\text{fitness}(\hat{\mathbf{x}}) > \text{fitness}(\mathbf{x})$, entonces se acepta el movimiento; en caso contrario, el movimiento se acepta si $\beta[\text{fitness}(\hat{\mathbf{x}}) + \text{fitness}(\mathbf{x})]/2 > \text{random}()$.

6. Recolectoras

Estado inicial en el algoritmo. Los puntos iniciales se escogen de manera aleatoria.

Para el desplazamiento, la escogencia de ambas dimensiones es aleatoria; el punto que define la dirección de la primera dimensión corresponde a uno de los óptimos locales escogido al azar, mientras que el punto que define la dirección para la segunda dimensión se escoge con una ruleta mediante la función de aptitud de cada punto.

Cambian de estado después de @c limit intentos en que no han mejorado su óptimo local.

7. Búsqueda

En el caso del estado de buscadora, el óptimo local se convierte en el punto de llegada, mientras que el punto de partida se genera de manera aleatoria en alguna de las caras del hipercubo. Para

generar el punto de salida en una de las caras, digamos $\mathbf{e} = (e_1, e_2, \dots, e_n)$ se requiere un número aleatorio $i \in \{1, 2, \dots, n\}$, y n números aleatorios $\mathbf{r} = (r_1, r_2, \dots, r_n) \in [0, 1)^n$, utilizando el siguiente algoritmo:

1. $e_j = x_j^{\min} + r_j(x_j^{\max} - x_j^{\min})$, $j \in \{1, 2, \dots, n\} - \{i\}$.
2. $e_i = (r_i < 0.5) ? x_i^{\min} : x_i^{\max}$ (Aquí se escogen una de las dos hipercaras en la i -ésima dimensión).

Para el movimiento de las abejas buscadoras, se escogen dos dimensiones; la primera se escoge mediante una ruleta (a mayor distancia con respecto al óptimo local, mayor probabilidad de escoger cierta dimensión) y se utiliza para acercarse al punto de llegada; mientras que la segunda se escoje al azar, y la dirección que se utiliza es para acercarse a uno de los óptimos locales seleccionados mediante una ruleta.

En caso de que la abeja se encuentre muy “cerca” del óptimo local, se genera nuevamente un punto en una de las caras y se reinicia el proceso.

En caso de que se encuentre un punto mejor que el óptimo local, se actualiza el óptimo local (obviamente) y se cambia el estado a recolectora.

Apéndice 4

En este apéndice aparece el ejecutable de la aplicación informática que utiliza el usuario.

Además se adjunta todos los registros de todas las pruebas realizadas al motor durante la ejecución del proyecto.

Por razones de espacio el apéndice 4 se adjunta de forma electrónica, en una memoria USB.